

# Análise da evolução espacial e fatores associados à morbimortalidade por Covid-19 nas regiões geográficas do Brasil: um estudo ecológico

## *Analysis of spatial evolution and factors associated with Covid-19 morbidity and mortality in the geographic regions of Brazil: an ecological study*

Jacques Antonio Cavalcante Maciel<sup>1</sup> , Jefferson Wyllian de Sousa Pará<sup>2</sup> , Ana Kamila Araújo Monteiro<sup>2</sup> , Francisca Elane dos Santos Araújo<sup>2</sup> , Jordânia Chaves de Siqueira<sup>2</sup> , Joelson Rosendo Sousa<sup>2</sup> , Igor Luco Castro-Silva<sup>2</sup> 

<sup>1</sup>Curso de Odontologia, Universidade Federal do Ceará (UFC) - Sobral (CE), Brasil.

<sup>2</sup>Universidade Federal do Ceará (UFC) - Sobral (CE), Brasil.

**Como citar:** Maciel JAC, Pará JWS, Monteiro AKA, Araújo FES, Siqueira JC, Sousa JR, et al. Análise da evolução espacial e fatores associados à morbimortalidade por Covid-19 nas regiões geográficas do Brasil: um estudo ecológico. Cad Saúde Colet, 2023; 31 (3):e31030512. <https://doi.org/10.1590/1414-462X202331030512>

### Resumo

**Objetivo:** Este estudo analisou a evolução do padrão de distribuição espacial dos coeficientes de morbimortalidade por Covid-19 e fatores associados nas Regiões Intermediárias de Articulação Urbana do Brasil. **Métodos:** Estudo ecológico com variáveis de bancos secundários, com dados de incidência e mortalidade por Covid-19 acumulados no intervalo de três meses, o que corresponde ao aumento das medidas de flexibilização do isolamento social. As variáveis independentes representaram fatores socioeconômicos. Foram realizadas análise de dependência espacial, regressão clássica e espacial. **Resultados:** Houve um aumento da morbimortalidade por Covid-19 entre os dois períodos analisados. Foi encontrada uma autocorrelação positiva com formação de cluster em áreas de maior incidência de Covid-19 e com maior significância em Regiões Intermediárias de Articulação Urbana na região Norte do Brasil, com agrupamentos maiores em relação à mortalidade após a flexibilização das medidas de isolamento. A ocorrência da morbimortalidade apresentou associação significativa com variáveis étnicas com maiores coeficientes de determinação na região Norte. **Conclusão:** Determinantes sociais demonstraram um comportamento preditivo no aumento da autocorrelação positiva para a mortalidade por Covid-19 durante os períodos observados, com aumento da morbimortalidade na região Norte após a flexibilização do isolamento social.

**Palavras-chave:** Covid-19, epidemiologia, análise espacial, estudos ecológicos.

### Abstract

**Background:** This study analyzed the evolution of the spatial distribution pattern of Covid-19 morbidity and mortality coefficients and associated factors in the Intermediate Regions of Urban Articulation in Brazil. **Method:** Ecological study with secondary bank variables with Covid-19 incidence and mortality data accumulated over the three-month interval, which corresponds to an increase in the measures for easing social isolation. The independent variables represented socioeconomic factors. Spatial dependence analysis, classical regression and spatial regression were performed. **Results:** There was an increase in Covid-19 morbidity and mortality between the two periods analyzed. A positive autocorrelation with



Este é um artigo publicado em acesso aberto (Open Access) sob a licença Creative Commons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Correspondência: Jacques Antonio Cavalcante Maciel. E-mail: [jacques.maciel@sobral.ufc.br](mailto:jacques.maciel@sobral.ufc.br)

Fonte de financiamento: nenhuma.

Conflito de interesses: nada a declarar.

Recebido em: Out. 21, 2020. Aprovado em: Abr. 17, 2021

cluster formation was found in areas with a higher incidence of Covid-19 and with greater significance in the Intermediate Regions of Urban Articulation in the North of Brazil, with larger clusters in relation to mortality after the relaxation of isolation measures. The occurrence of morbidity and mortality was significantly associated with ethnic variables, with higher coefficients of determination in the North. **Conclusion:** Social determinants demonstrated a predictive behavior in the increase of positive autocorrelation for mortality due to Covid-19 during the observed periods, with an increase in morbidity and mortality in the North region after the relaxation of social isolation.

**Keywords:** Covid-19, epidemiology, spatial analysis, ecological studies.

## INTRODUÇÃO

Em 21 de dezembro de 2019 em Wuhan, cidade com uma população de mais de 11 milhões pertencente à província de Hubei, na China, foi identificado um grupo de pacientes com pneumonia de etiologia desconhecida, posteriormente identificada como a Doença do Novo Coronavírus 2019 (Covid-19), causada por um novo tipo de coronavírus (2019-nCoV)<sup>1</sup>.

Em 30 de janeiro, o Diretor-Geral da Organização Mundial de Saúde (OMS) declarou o surto de Covid-19 uma emergência de saúde pública de interesse internacional. A declaração foi acompanhada de recomendações relacionadas à detecção precoce da infecção, isolamento e tratamento de casos infectados, rastreamento de contatos e medidas de distanciamento social que correspondam ao nível de risco em cada país, com o objetivo principal de interromper ou atrasar e limitar a propagação do vírus<sup>2</sup>.

A disseminação da pandemia se estendeu para toda a Ásia e outras regiões do mundo. Em 25 de fevereiro de 2020, o Brasil confirmou o primeiro caso<sup>3</sup>. Diante da ausência de tratamento efetivo, as únicas decisões que se tornaram consensuais na comunidade científica foram isolamento social, adoção de medidas de higiene básica, uso de equipamentos de proteção (máscaras e luvas) e aplicação de testes para identificação das pessoas contaminadas.

No Brasil, a Lei n. 13.979/2020, que dispõe sobre as medidas para enfrentamento da Covid-19 no país, já estava em vigor desde 7 de fevereiro de 2020. Cerca de três meses após o início da adoção de medidas de isolamento e restrições de circulação e de funcionamento do comércio adotadas pelos estados e o pelo Distrito Federal, algumas unidades da federação apresentaram padrões diferenciados de restrição e afrouxamento das regras, assim como definiram planos para a retomada gradual das atividades econômicas, mantendo medidas de isolamento social<sup>4</sup>. O boletim epidemiológico 07 da Covid-19, de 6 de abril de 2020, recomendou que as unidades federadas fizessem a transição para o distanciamento seletivo se o número de casos confirmados não tiver ocupado mais de 50% da capacidade instalada dos serviços de saúde existente antes da pandemia<sup>5</sup>.

A diversidade de condutas não desacelerou o comportamento da pandemia. De acordo com os dados da OMS, no momento de escrita do presente estudo (11 de setembro de 2020), o mundo possuía 28.040.853 casos confirmados de Covid-19, incluindo 906.092 mortes. O continente americano possuía 14.447.680 casos confirmados. O Brasil até então era o terceiro país do mundo com maior número de casos (4.197.889), atrás da Índia (4.562.414) e dos Estados Unidos (6.304.181). Mesmo com um processo de flexibilização avançado, o número de mortes no Brasil era de 128.439<sup>6</sup>.

Ferramentas de geoprocessamento e análises espaciais refletem a magnitude da morbimortalidade e a distribuição da doença em diferentes escalas, subsidiando a tomada de decisões, bem como a adoção de estratégias mais restritivas e/ou a priorização de locais com maior incidência da doença, investigando suas causas e/ou alocando maior quantidade de insumos<sup>7-10</sup>.

Mesmo com a utilização de Sistemas de Informação Geográfica para mapear a distribuição e difusão da pandemia, observa-se uma carência de estudos sobre disparidades geográficas e sociais da pandemia no território brasileiro. Dados que exploram os fatores de risco associados a infecções e fatalidades por Covid-19 são necessários para informar as políticas, incluindo preparação, resposta, estratégias de mitigação e recuperação<sup>11</sup>.

A doença teve um contexto inicial associado a espacialidades de alto desenvolvimento humano, difundindo-se posteriormente para outros estratos sociais da população<sup>12</sup>. O contexto

desses públicos relaciona a convergência dos marcadores sociais que atuam distintamente, vulnerabilizando-os em sua individualidade. Além disso, a Covid-19 apresenta, em sua maioria, sintomatologia leve, contudo pode desenvolver quadros graves em grupos específicos, a exemplo das populações com piores condições socioeconômicas<sup>13</sup>.

Este estudo teve como objetivo analisar a evolução do padrão de distribuição espacial dos coeficientes de morbimortalidade de Covid-19 e sua relação com fatores socioeconômicos em Regiões Intermediárias de Articulação Urbana (RIAU) do Brasil em dois momentos distintos.

## MÉTODOS

Trata-se de um estudo ecológico, exploratório e analítico, cujas unidades de análise foram as RIAU do Brasil, tendo em vista a complexidade e desigualdade da distribuição populacional no território brasileiro. As orientações da iniciativa *Strengthening the Reporting of Observational Studies in Epidemiology* (STROBE) foram seguidas para organizar o estudo a partir de seu desenho metodológico<sup>14</sup>.

O Brasil apresenta 161 RIAU, as quais fazem parte de um modelo de Divisão Urbano Regional o qual constituiu um recorte territorial em três níveis de Regiões de Articulação Urbana classificadas em Ampliadas, Intermediárias e Imediatas. As RIAU são formadas por um grupo de municípios e uma cidade polo, que exerce influência em termos macrorregionais e se caracteriza por apresentar uma articulação interna baseada no oferecimento e busca de bens e serviços de alta complexidade<sup>15</sup>.

Os dados de incidência e mortalidade por Covid-19 acumulados foram coletados de 5.570 municípios do Brasil através dos boletins epidemiológicos e/ou painéis interativos disponibilizados pelas secretarias estaduais de saúde das unidades da Federação e do Distrito Federal em dois momentos distintos, para que pudesse ser observada a ocorrência da morbimortalidade com base na evolução da implementação das medidas de flexibilização. O primeiro momento de observação (T1) corresponde à observação dos casos agregados desde o primeiro caso confirmado de Covid-19 até as 18h do dia 7 de maio de 2020 e a segunda observação (T2), aos casos agregados do dia 8 de maio até as 18h do dia 7 de agosto de 2020.

Esses valores municipais de incidência e mortalidade foram agregados por RIAU. Em seguida, para construção de coeficientes, os dados acumulados foram divididos pela população suscetível, que para este estudo foram os valores das populações municipais estimadas para 2019 pelo Instituto Brasileiro de Geografia e Estatística (IBGE), agregadas também por RIAU.

Os coeficientes gerados foram multiplicados pela base populacional de 100.000 habitantes (hab) para que assim fossem obtidos, para cada RIAU, o coeficiente de incidência (CI1) e o coeficiente de mortalidade (CM1) referentes à T1 e o coeficiente de incidência (CI2) e o coeficiente de mortalidade (CM2) referentes à T2.

Os dados socioeconômicos foram retirados do Censo Demográfico de 2010<sup>16</sup> e serviram de base para construir os indicadores utilizados nas análises dos dados por RIAU: Número médio de pessoas por domicílio (POP\_DOM); Renda familiar média (RM\_DOM); Proporção de analfabetos (ANALF); Taxa de alfabetização das pessoas de 10 anos ou mais de idade por sexo (POP\_ALF); Proporção de domicílios com banheiro de uso exclusivo, energia elétrica, abastecimento de água potável e com coleta de lixo (POP\_ALESG); Proporção de cor de pele declarada branca (P\_BRA); Proporção de cor de pele declarada preta (P\_PRE); Proporção de cor de pele declarada amarela (P\_AM); Proporção de cor de pele declarada parda (P\_PAR); Proporção de cor de pele declarada indígena (P\_IND). Os indicadores foram construídos com o objetivo de contemplar as dimensões de renda, escolaridade e condições de habitação.

Para suavização dos coeficientes de incidência e mortalidade detectados por cada RIAU também foi calculado o Estimador Bayesiano Local, que faz um cálculo baseado também na média dos seus vizinhos<sup>17</sup>. A graduação dos valores se deu por quebras naturais (*jerks*). Foi criada uma Matriz de Proximidade por contiguidade do tipo rainha, correspondendo a todos as RIAU vizinhas. O Índice de Moran foi calculado para verificar a dependência espacial da distribuição dos coeficientes. Considerou-se o nível de significância de 5%. O Índice de Moran varia de -1 a

+1: valores significativos positivos mostram uma autocorrelação positiva; valores significativos negativos indicam autocorrelação espacial negativa<sup>12,17</sup>.

Essa visualização da dependência se deu através do MoranMap a fim de identificar áreas com altos valores e vizinhos em igual condição (Padrão Alto-Alto), áreas com baixos valores e com vizinhança também em igual condição (Padrão Baixo-Baixo), ou ainda áreas em transição (Padrão Alto-Baixo e Padrão Baixo-Alto) e áreas sem significância. A visualização desses clusters com autocorrelação espacial positiva com base nos níveis estatisticamente significantes foi demonstrada através do *Local Indicators of Spatial Association* (LisaMap)<sup>12</sup>.

Com relação aos modelos multivariados de regressão espacial, foram analisadas as variáveis dependentes CI11 e o CM1 referentes à T1 e CI2 e CM2 referentes à T2 para cada RIAU e variáveis independentes, sociais, econômicas, ambientais e de atenção à saúde, utilizando-se análise de regressão clássica através dos modelos de mínimos quadrados ordinários (*Ordinary Least Squares* – OLS) e regressão espacial ponderada (*Geographically Weighted Regression* – GWR).

O método OLS gera um modelo de regressão linear que procura explicar a relação global entre a variável independente e as variáveis dependentes. O método GWR, por sua vez, tem seus coeficientes estimados localmente, a partir da variabilidade espacial em cada área. Assim, os coeficientes de cada variável que foram significativos no modelo geral (OLS) foram testados no modelo local (GWR)<sup>17</sup>. O modelo foi escolhido com base no critério de informação de Akaike (AIC) e melhor R<sup>2</sup> ajustado, métodos clássicos de seleção de variáveis dependentes no modelo de regressão multivariada.

Para avaliar o desempenho dos modelos OLS (clássico) e GWR (espacial), estes foram comparados considerando-se como parâmetros o R<sup>2</sup> ajustado, o AIC e a menor variabilidade dos resíduos resultantes de cada modelo. O modelo OLS foi processado no programa GeoDa, versão 1.10.0.8 (Spatial Analysis Laboratory, University of Illinois at Urbana-Champaign, EUA)<sup>18</sup>. O modelo GWR foi implementado com o programa GWR4 (Arizona State University, School of Geographical Sciences & Urban Planning), versão 4.0<sup>19</sup>. Os mapas coropléticos foram gerados no software QGIS, versão 3.10<sup>20</sup>.

Foram utilizados dados secundários de domínio público, o que, conforme a Resolução n. 510/2016 do Conselho Nacional de Saúde, dispensa aprovação de comitê de ética em pesquisa com seres humanos<sup>21</sup>.


## RESULTADOS

Em 7 de maio de 2020 o Brasil apresentava 709.810 casos confirmados e 36.785 óbitos, já em 7 de agosto de 2020 esses valores aumentaram para 2.836.194 casos confirmados (aumento de 2.126.384 casos) e 98.641 óbitos acumulados (aumento de 61.856 óbitos). As curvas epidemiológicas de casos novos e acumulados para cada momento estão representadas no Gráfico 1.

Inicialmente CI1 foi de 277,88/100.000hab (com a RIAU de valor mínimo Bom Jesus da Lapa, na Bahia, com 17,83/100.000hab e valor máximo Tabatinga, no Amazonas, com 2.853,97/100.000hab) e CM1, de 31,60/100.000hab (com a RIAU de valor mínimo Irecê, na Bahia, com 0,28/100.000hab e valor máximo Tabatinga, no Amazonas, com 66,31/100.000hab). Em T2, o CI2 foi de 1.011,85/100.000hab (com a RIAU de valor mínimo Recife, em Pernambuco, com 63,94/100.000hab e valor máximo Boa Vista, em Roraima, com 4.728,59/100.000hab) e CM2, de 29,43/100.000hab (com a RIAU de valor mínimo Ponte Nova, em Minas Gerais, com 2,43/100.000hab e valor máximo Boa Vista, em Roraima, com 64,87/100.000hab) (Figura 1).

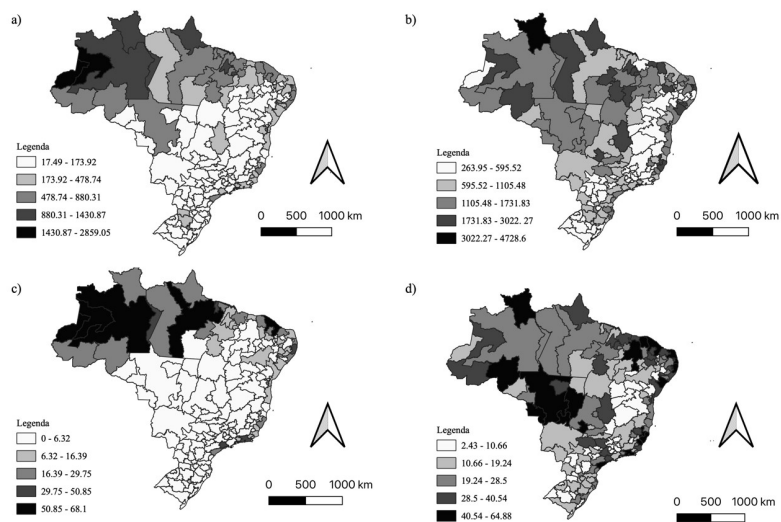
Na análise do Índice de Moran ( $I_M$ ) segundo os coeficientes de prevalência e mortalidade foi identificada autocorrelação espacial positiva significativa em toda a extensão territorial, tanto para T1 ( $I_{M,CI1}=0,622$ ;  $I_{M,CM1}=0,619$   $p<0,001$ ) quanto para T2 ( $I_{M,CI2}=0,440$ ;  $I_{M,CM2}=0,529$   $p<0,001$ ).

Em relação à dependência espacial no MoranMap, em CI1 (Figura 2a) foi identificado agrupamento do tipo Alto-Alto nas RIAU dos estados do Acre (Rio Branco), Amazonas (Tabatinga, Tefé, Manaus, Parintins), Roraima (Boa Vista), Pará (Santarém e Belém), Maranhão (Imperatriz, Pinheiro, São Luís, Pedreiras, Caxias e Bacabal). Foram identificados três



**Gráfico 1.** Curva de morbimortalidade por Covid-19 no Brasil até 7 de agosto de 2020 (1a – Casos novos; 1b – Casos acumulados; 1c – Óbitos novos; 1d – Óbitos acumulados).

Fonte: Ministério da Saúde<sup>22</sup>



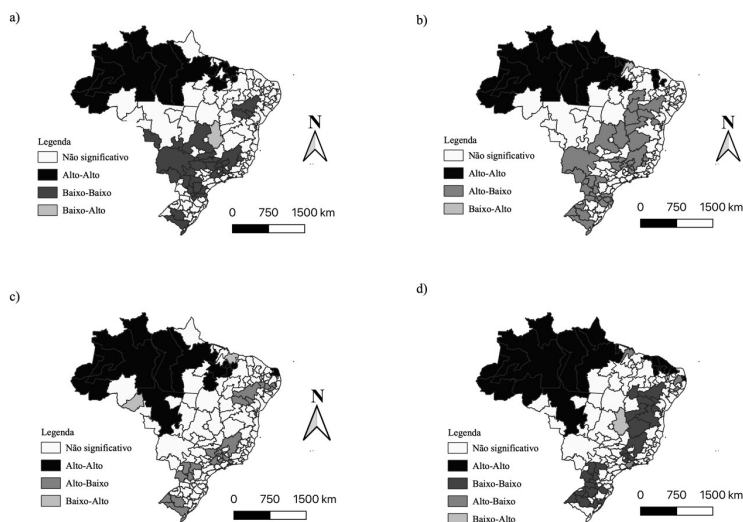
**Figura 1.** Distribuição espaço-temporal da morbimortalidade por Covid-19 nas RIAU do Brasil (1a. CI1; 1b. CI2; 1c. CM1; 1d. CM2).

Fonte: Ministério da Saúde<sup>22</sup>

agrupamentos Baixo-Baixo, o primeiro composto pelas RIAU dos estados de Mato Grosso (Cáceres e Rondonópolis), Mato Grosso do Sul (Campo Grande), Goiás (Goiânia), Minas Gerais (Uberlândia, Uberaba, Passos, Divinópolis, Belo Horizonte, Ipatinga, Varginha, Itajubá e Alfenas), São Paulo (São José do Rio Preto, Ribeirão Preto, Campinas e Presidente Prudente), Paraná

(Maringá, Londrina, Ponta Grossa, Guarapuava e Curitiba) e Santa Catarina (Joinville e Caçador). Um segundo agrupamento foi formado nos estados de Pernambuco (Petrolina) e Bahia (Irecê e Jacobina) e um terceiro no Rio Grande do Sul (Santa Maria e Pelotas). Em CM1 (Figura 2b) foram identificados dois agrupamentos do tipo Alto-Alto, o primeiro nos estados do Acre (Rio Branco), Amazonas (Tabatinga, Tefé, Manaus e Parintins), Amapá (Macapá), Pará (Boa Vista, Santarém, Bragança, Capanema, Castanhal e Belém), Maranhão (Imperatriz, São Luís e Pedreiras) e o segundo no estado do Ceará (Sobral, Crateús e Quixadá).

Em CI2 (Figura 2c) foi identificado agrupamento do tipo Alto-Alto nas RIAU dos estados do Acre (Rio Branco), Amazonas (Tabatinga, Tefé, Manaus e Parintins), Roraima (Boa Vista), Pará (Santarém e Belém), Maranhão (Imperatriz, Pinheiro, Pedreiras, Caxias, Bacabal e Presidente Dutra), Mato Grosso (Cuiabá) e Tocantins (Araguaína). A RIAU de Natal, no Rio Grande do Norte, também apresentou padrão Alto-Alto. Em CM2 (Figura 2d), dois agregados Alto-Alto foram identificados, o primeiro ainda abrangendo os estados do Acre (Rio Branco), Amazonas (Tabatinga, Tefé, Manaus e Parintins), Roraima (Boa Vista), Pará (Santarém e Belém), Maranhão (Imperatriz, Pinheiro, São Luís, Pedreiras, Caxias e Bacabal), Mato Grosso (Cuiabá) e Rondônia (Porto Velho) e o segundo composto por Ceará (Sobral, Fortaleza e Crateús), Rio Grande do Norte (Mossoró) e Paraíba (João Pessoa). Os agrupamentos Baixo-Baixo abrangeram Pernambuco (Petrolina), Bahia (Irecê, Bom Jesus da Lapa, Itaberaba e Vitória da Conquista), Piauí (Corrente e Bom Jesus), Minas Gerais (Montes Claros, Belo Horizonte, Passos, Alfenas, Varginha e Pouso Alegre). Um segundo agrupamento foi identificado nas RIAU dos estados do Paraná (Maringá, Londrina, Guarapuava, Pato Branco e Cascavel), Santa Catarina (Chapecó), Rio Grande do Sul (Passo Fundo, Lages, Ijuí, Cruz Alta, Santa Maria, Uruguaiana e Porto Alegre).



**Figura 2.** MoranMap da autocorrelação da morbimortalidade por Covid-19 nas RIAU do Brasil (2a. CI1; 2b. CM1; 2c. CI2; 2d. CM2).

**Fonte:** Ministério da Saúde<sup>22</sup>

Após análise das variáveis sociodemográficas pela análise OLS, foram incluídos no modelo apenas os preditores com maior potencial para explicar a morbimortalidade por Covid-19 nas RIAU, a saber: P\_PRE, P\_PAR, P\_IND e ANALF.

A Tabela 1 apresenta resultados do modelo de regressão espacial para CI1, em que GWR ( $R^2$  ajustado = 0.453497) e OLS ( $R^2$  ajustado = 0.324873). Para CM1, GWR ( $R^2$  ajustado = 0.601266) e OLS ( $R^2$  ajustado = 0.324873); para CI2, GWR ( $R^2$  ajustado = 0.208129) e OLS ( $R^2$  ajustado = 0.138488); para CM2, GWR ( $R^2$  ajustado = 0.220663) e OLS ( $R^2$  ajustado = 0.110430), o que

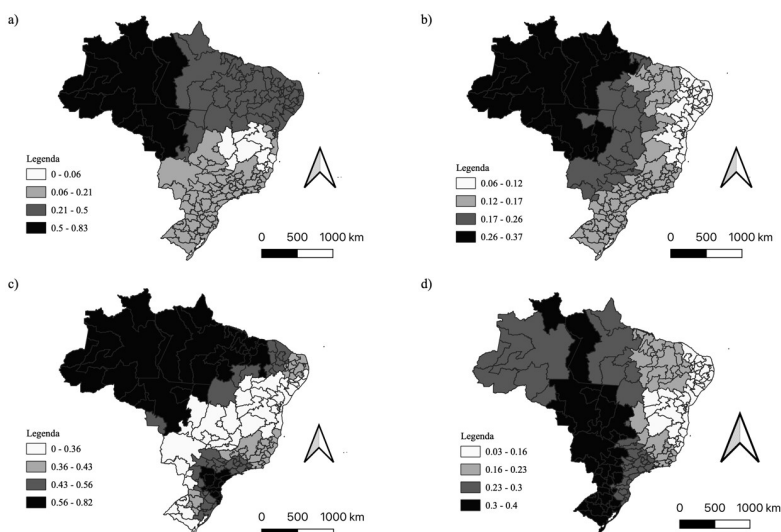
destaca maior poder preditivo do modelo GWR. Também se obteve como maiores valores de coeficientes para as variáveis P\_PAR e P\_IND; as variáveis P\_PRE e ANALF apresentaram coeficientes negativos.

Na Figura 3a, na associação espacial local entre CI1 e as variáveis independentes foi verificado que coeficientes de determinação ( $R^2$ ) entre os valores observados e os valores do modelo GWR foram relativamente heterogêneos no Brasil. Os maiores coeficientes positivos foram observados em boa parte da região Norte e em municípios do estado do Mato Grosso (Figura 3a). Os menores valores de  $R^2$  encontravam-se no restante das regiões Centro-Oeste,

**Tabela 1.** Resultado das análises do modelo de regressão global (OLS) e do modelo de regressão ponderada local (GWR) em relação às variáveis dependentes nas RIAU do Brasil

	OLS				GWR			
	Coeficiente de Regressão Padronizado				Média			
	CI1	CI2	CM1	CM2	CI1	CI2	CM1	CM2
Intercepto	-19.319	517.936	0.008	13.669	-136.278	330.455	4.028	19.464
P_PRE	-14.524*	-7.886	-0.737*	-0.367	-7.024	-0.685	-0.420	-0.169
P_PAR	8.337*	14.233	0.425*	0.297*	8.506	17.402	0.433	0.341
P_IND	54.091*	38.131	1.187*	0.403	9.052	4.085	3.435	0.404
ANALF	-3.235	-8.675	-0.442*	-0.175	-6.782	-20.303	-1.087	-0.922
$R^2$	0.467	0.160	0.341	0.132	0.685	0.300	0.698	0.311
AIC	2281.79	2548.13	1227.1	1282.08	2215.783	2540.597	1155.822	1266.821
I	0.165	0.010	0.069	0.059	-	-	-	-
ANOVA Teste F	34.192*	7.429*	20.248*	5.965*	8.559	2.095	4.230	2.712

\* Índice de Moran



**Figura 3.** Mapas com resultados da análise GWR e indicação dos coeficientes de determinação entre a morbimortalidade por Covid-19 e as variáveis independentes testadas para as RIAU do Brasil (3a. CI1; 3b. CM1; 3c. CI2; 3d. CM2).

Fonte: Ministério da Saúde<sup>22</sup>

Sudeste e Sul. Com relação à associação entre CM1 e as variáveis independentes (Figura 3b), maiores coeficientes de determinação permaneciam predominantemente na região Norte e parte das regiões Nordeste e Sudeste. Na segunda observação, CI2 continuou apresentando R<sup>2</sup> de maior valor nas regiões Norte e Centro-Oeste (3c). Em CM2 (3d), observou-se diminuição do coeficiente na região Norte, porém com abrangência das regiões Centro-Oeste, Sul e Sudeste.

## DISCUSSÃO

Os achados deste estudo evidenciaram uma dependência espacial positiva dos coeficientes de morbimortalidade por Covid-19 nos dois momentos de observação com identificação de fatores preditivos utilizando as RIAU como unidade amostral. A opção por análise espacial com RIAU se deu em virtude dos fluxos existentes na estrutura da região orientarem a gestão regionalizada de saúde, já que a maioria de leitos de UTI-COVID encontram-se em municípios polos das RIAU. Ademais, esse critério de agrupamento é bem semelhante ao das Regiões de Saúde que utilizam o compartilhamento de ações e serviços de saúde<sup>23</sup>.

Assim, o percurso metodológico escolhido valida a utilização de estudos ecológicos com análise espacial para o apoio na tomada de decisão dos serviços de saúde em Regiões de Saúde. Isso demonstra que na ausência de recursos e tempo, a priorização de áreas vulneráveis à ocorrência dos desfechos investigados na prestação de serviços de saúde de forma equânime<sup>24,25</sup>.

Na análise temporal, a primeira observação identificou um aumento de agregado do tipo Alto-Alto concentrado na região Norte na prevalência de Covid-19 e na segunda observação houve uma diluição, porém com a maior extensão ainda na região Norte, na qual o estado do Amazonas é considerado um dos epicentros da pandemia no Brasil, possuindo no momento de escrita deste estudo 271 leitos de UTI para casos de Covid-19 (6,5 leitos/100.000 hab)<sup>26</sup>.

A análise da autocorrelação espacial utilizando o Índice de Moran apresentou-se como uma medida sensível para verificar a dependência espacial em T1 e T2, sendo utilizada em associação à capacidade de sistemas de saúde na China, a partir dos primeiros surtos de Covid-19 em Wuhan, na China<sup>27</sup>. O Índice de Moran juntamente com a análise LISA demonstraram autocorrelação espacial positiva, sugerindo a necessidade da manutenção e intensificação de estratégias de controle, como o distanciamento social, nessas regiões da cidade, para que se reduza a velocidade de transmissão do SARS-CoV-2 e, conseqüentemente, se evite o aumento de óbitos. Tal padrão chama a atenção para a necessidade de um plano de mitigação ou supressão da doença considerando-se os contextos e realidades sociais<sup>28,29</sup>.

Conforme a análise de regressão utilizando GWR pode demonstrar, as diferenças espaço-temporais na morbimortalidade por Covid-19 entre as RIAU do Brasil refletiram desigualdades sociais, econômicas e estruturais existentes na região Norte do país<sup>30</sup>. Um exemplo brasileiro é que, na análise dos primeiros casos no Rio de Janeiro, bairros da Zona Norte do município apresentaram maiores coeficientes de mortalidade, mesmo quando comparados com bairros da Zona Sul que possuíam maior incidência<sup>28</sup>. Um estudo no Iran observou que o fluxo de pessoas faz com que a incidência aumente, como em áreas de maior concentração e mobilidade urbana<sup>31</sup>, o que pode ser observado no agrupamento formado em P2 envolvendo o estado do Ceará.

Um estudo espacial na África associou a Argélia, nação africana mais atingida (no momento da redação) pelo vírus (estimado em termos do número de mortes registradas), e também estabeleceu uma relação linear entre o número de casos confirmados e o número de mortes atribuíveis<sup>32</sup>, semelhante ao que se observou nas RIAU pertencentes à região Norte.

Apesar de aspectos relacionados à densidade populacional, diferenças étnicas também foram associadas ao aumento da incidência<sup>31</sup>. Nesse sentido, não há uma solução única para todo o país, mas as políticas devem observar as singularidades regionais<sup>30</sup>. Conforme o percurso metodológico adotado para fatores sociais, o modelo de regressão espacial multivariado GWR é o mais adequado para mensurar em comparação com modelo de regressão clássica<sup>7,33</sup>.

Em Nova York nos Estados Unidos, as áreas com proporções simultaneamente altas de testes positivos e população negra estão concentradas no leste do Brooklyn, no sudeste do



Queens e em partes do Bronx. As áreas com distribuição conjunta de baixa escolaridade e alta proporção de testes positivos abrangem uma ampla proporção desses bairros. Este estudo adiciona à literatura anterior que identificou minorias raciais/étnicas e aquelas com status socioeconômico mais baixo em risco aumentado em uma gama de resultados de saúde, incluindo epidemias de doenças infecciosas anteriores<sup>34,35</sup>.

Além disso, outro resultado do estudo é que estados mais desiguais apresentaram progressão mais acentuada nos coeficientes de incidência e mortalidade por Covid-19, enquanto entre os menos desiguais ocorreram aumentos sutis. Pessoas em maior desvantagem socioeconômica tendem a ter uma exposição diferencial ao vírus por terem habitações de pior qualidade, viverem em maior número de pessoas, em residências menores, usarem transporte público com maior aglomeração e terem insegurança laboral que dificulta o distanciamento social<sup>36</sup>.

Também relevante é a falta de estratégia regional que considere a heterogeneidade territorial para entender as formas como a epidemia se difunde espacialmente, visto que a proporção de óbitos de pacientes pretos e pardos foi maior que a de brancos, por faixa etária, nível de escolaridade e em municípios de Índice de Desenvolvimento Humano elevado, sendo a chance de morte de um paciente preto ou pardo analfabeto 3,8 vezes maior que a de um paciente branco com nível superior<sup>37</sup>.

Para a população negra, o cenário da pandemia se associa a condições desiguais determinadas pelo racismo estrutural e institucional<sup>38</sup>. Em maio de 2020, além de pretos e pardos conformarem a maior parte das notificações, o percentual de pacientes pretos e pardos que vieram a óbito (54,78%) foi maior do que o de brancos (37,93%)<sup>39</sup>.

A adesão ao isolamento, por exemplo, depende, além de outras questões, de medidas de proteção social que garantam recursos para a população economicamente mais vulnerável. No caso do Brasil, o auxílio emergencial previsto na lei n. 13.982/2020, modificada por texto substitutivo do Projeto de Lei n. 873/2020, que amplia o auxílio emergencial de R\$ 600,00 para mais categorias de pessoas em condições vulneráveis é considerado insuficiente<sup>40</sup>.

Neste estudo, por os dados secundários originarem-se de distintas fontes oficiais de cada secretaria estadual de saúde, não é possível afirmar que pessoas mais vulneráveis economicamente foram as mais atingidas, mas sim que há uma probabilidade de que, em regiões mais desiguais, o impacto da pandemia pode ser mais severo em toda população. Tendo em vista que o Brasil não realiza testagem em massa, a subnotificação de casos e óbitos por Covid-19 pode influenciar os resultados deste estudo, assim como, dada a velocidade na mudança do quadro da doença no Brasil, os resultados podem sofrer alterações.

Por fim, a autocorrelação positiva com formação de cluster em áreas de maior prevalência de Covid-19 localizadas, com maior significância, em RIAU da região Norte do Brasil – com agrupamentos maiores em relação à mortalidade após a flexibilização das medidas de isolamento – requer um olhar direcionado às políticas de enfrentamento da pandemia no Brasil.

Ainda que a flexibilização de medidas de isolamento social tenha ocorrido na maioria das RIAU no Brasil, houve um considerável aumento da morbimortalidade por Covid-19 com ênfase na região Norte. A ocorrência da morbimortalidade apresentou associação significativa com fatores étnicos e educacionais, tendo em vista que as variáveis preditivas “percentual de população negra, parda e indígena e percentual da população analfabeta” estão associadas a altas taxas de prevalência e mortalidade por Covid-19 na região Norte e Nordeste do Brasil, com maiores coeficientes de determinação.

## REFERÊNCIAS

1. Huang R, Liu M, Ding Y. Spatial-temporal distribution of Covid-19 in China and its prediction: a data-driven modeling analysis. *J Infect Dev Ctries*. 2020;14(3):246-53. <http://dx.doi.org/10.3855/jidc.12585>. PMID:32235084.
2. Salama AM. Coronavirus questions that will not go away: interrogating urban and socio-spatial implications of Covid-19 measures. *Emerald Open Res*. 2020;2:14. <http://dx.doi.org/10.35241/emeraldopenres.13561.1>.

3. Rodriguez-Morales AJ, Gallego V, Escalera-Antezana JP, Méndez CA, Zambrano LI, Franco-Paredes C, et al. Covid-19 in Latin America: The implications of the first confirmed case in Brazil. *Travel Med Infect Dis.* 2020;35:101613. <http://dx.doi.org/10.1016/j.tmaid.2020.101613>. PMID:32126292.
4. Aquino EML, Silveira IH, Pescarini JM, Aquino R, de Souza-Filho JA, Rocha AS, et al. Medidas de distanciamento social no controle da pandemia de Covid-19: potenciais impactos e desafios no Brasil. *Cien Saude Colet.* 2020;25(Supl 1):2423-46. <http://dx.doi.org/10.1590/1413-81232020256.1.10502020>. PMID:32520287.
5. Brasil. Boletim Epidemiológico No. 07 do Centro de Operações de Emergência em Saúde Pública [Internet]. Vol. 6. Brasília: Ministério da Saúde; 2020 [citado em 2020 Set 11]. Disponível em: <https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/boletins/epidemiologicos/covid-19/2020/boletim-epidemiologico-no-7-boletim-coe-coronavirus.pdf/view>
6. World Health Organization. WHO Coronavirus Disease (Covid-19) Dashboard [Internet]. Geneva: WHO; 2020 [citado em 2020 Set 11]. p. 1-7. Disponível em: <https://covid19.who.int/>
7. Guliyev H. Determining the spatial effects of Covid-19 using the spatial panel data model. *Spat Stat.* 2020;38:10044343. <http://dx.doi.org/10.1016/j.spasta.2020.100443>. PMID:32292691.
8. Hong JY, Jeon JY. Exploring spatial relationships among soundscape variables in urban areas: A spatial statistical modelling approach. *Landsc Urban Plan.* 2017;157:352-64. <http://dx.doi.org/10.1016/j.landurbplan.2016.08.006>.
9. Zhou C, Su F, Pei T, Zhang A, Du Y, Luo B, et al. Covid-19: challenges to GIS with Big Data. *Geogr Sustain.* 2020;1(1):77-87. <http://dx.doi.org/10.1016/j.geosus.2020.03.005>.
10. Cardoso PV, Seabra VDS, Bastos IB, Porto Costa EDC. A importância da análise espacial para tomada de decisão: um olhar sobre a pandemia de Covid-19. *Rev Tamoios.* 2020;16(1):125-37. <http://dx.doi.org/10.12957/tamoios.2020.50440>.
11. Zhang CH, Schwartz GG. Spatial disparities in Coronavirus Incidence and Mortality in the United States: an ecological analysis as of may 2020. *J Rural Health.* 2020;36(3):433-45. <http://dx.doi.org/10.1111/jrh.12476>. PMID:32543763.
12. Maciel JAC, Castro-Silva II, de Farias MR. Initial analysis of the spatial correlation between the incidence of Covid-19 and human development in the municipalities of the state of Ceará in Brazil. *Rev Bras Epidemiol.* 2020;23:e200057. PMID:32578812.
13. Estrela FM, Soares CFS, Cruz MA, Silva AF, Santos JRL, Moreira TM, et al. Pandemia da Covid 19: refletindo as vulnerabilidades a luz do gênero, raça e classe. *Cien Saude Colet.* 2020;25(9):3431-6. <http://dx.doi.org/10.1590/1413-81232020259.14052020>. PMID:32876261.
14. Malta M, Cardoso LO, Bastos FI, Magnanini MMF, Silva CMFP. STROBE initiative: guidelines on reporting observational studies. *Rev Saude Publica.* 2010;44(3):1-5. PMID:20549022.
15. Brasil. Divisão Urbano Regional: procedimentos operacionais [Internet]. Brasília: Ministério da Saúde; 2013 [citado em 2020 Set 11]. Disponível em: [ftp://geoftp.ibge.gov.br/organizacao\\_do\\_territorio/divisao\\_regional/divisao\\_urbano\\_regional/documentacao/divisao\\_urbano\\_regional\\_apresentacao\\_do\\_trabalho.pdf](ftp://geoftp.ibge.gov.br/organizacao_do_territorio/divisao_regional/divisao_urbano_regional/documentacao/divisao_urbano_regional_apresentacao_do_trabalho.pdf)
16. Brasil. IBGE Censo 2010 - Paineis [Internet]. 2020 [citado em 2020 Ago 7]. Disponível em: <https://censo2010.ibge.gov.br/painel/>
17. Freire MHS, Barros APMM, Andrade L, Nihei OK, Fontes KB. Geospatial analysis of births with congenital disorders, Paraná, 2008-2015: ecological study. *Rev Bras Enferm.* 2020;73(3):e20180741. <http://dx.doi.org/10.1590/0034-7167-2018-0741>. PMID:32321126.
18. Anselin L, Syabri I, Kho Y. GeoDa: an introduction to spatial data analysis. *Geogr Anal.* 2006;38(1):5-22. <http://dx.doi.org/10.1111/j.0016-7363.2005.00671.x>.
19. GWR4. GWR 4 Software Downloads [Internet]. Vol. 4. Tempe: Arizona State University; 2020 (Geographically Weighted Regression) [citado em 2020 Ago 10]. p. 3-5. Disponível em: <https://sgsup.asu.edu/sparc/gwr4>
20. QGIS Development Team. QGIS - A Free and Open Source Geographic Information System [Internet]. 2020 [citado em 2020 Ago 10]. p. 2. Disponível em: <https://www.qgis.org/en/site/>
21. Guerriero ICZ. Resolução nº 510 de 7 de abril de 2016 que trata das especificidades éticas das pesquisas nas ciências humanas e sociais e de outras que utilizam metodologias próprias dessas áreas. *Cien Saude Colet.* 2016;21(8):2619-29. <http://dx.doi.org/10.1590/1413-81232015218.17212016>. PMID:27557034.
22. Brasil. Ministério da Saúde. Painel Coronavírus [Internet]. Brasília: Ministério da Saúde; 2023 [citado em 2020 Ago 10]. Disponível em: [covid.saude.gov.br](https://covid.saude.gov.br)
23. Marinho CSR, Flor TBM, Pinheir JMF, Ferreira MAF. Objetivos de Desenvolvimento do Milênio: impacto de ações assistenciais e mudanças socioeconômicas e sanitárias na mortalidade de crianças. *Cad Saude Publica.* 2020;36(10):e00191219. <http://dx.doi.org/10.1590/0102-311x00191219>. PMID:33084833.

24. Lakhani A. Which melbourne metropolitan areas are vulnerable to Covid-19 based on age, disability, and access to health services? Using spatial analysis to identify service gaps and inform delivery. *J Pain Symptom Manage.* 2020;60(1):e41-4. <http://dx.doi.org/10.1016/j.jpainsymman.2020.03.041>. PMID:32276097.
25. Jiang P, Fu X, Fan Y, Klemeš JJ, Chen P, Ma S, et al. Spatial-temporal potential exposure risk analytics and urban sustainability impacts related to Covid-19 mitigation: a perspective from car mobility behaviour. *J Clean Prod.* 2020;279:e123673. <http://dx.doi.org/10.1016/j.jclepro.2020.123673>. PMID:32836914.
26. Brasil. Ministério da Saúde. SRAG casos por região [Internet]. Brasília: CoronaVírus Brasil; 2020 [citado em 2020 Ago 10]. p. 2816. Disponível em: [covid.saude.gov.br](https://covid.saude.gov.br)
27. Kang D, Choi H, Kim JH, Choi J. Spatial epidemic dynamics of the Covid-19 outbreak in China. *Int J Infect Dis.* 2020;94:96-102. <http://dx.doi.org/10.1016/j.ijid.2020.03.076>. PMID:32251789.
28. Cavalcante JR, Abreu AJL. Covid-19 no município do Rio de Janeiro: análise espacial da ocorrência dos primeiros casos e óbitos confirmados. *Epidemiol Serv Saude.* 2020;29(3):e2020204. <http://dx.doi.org/10.5123/S1679-49742020000300007>. PMID:32520107.
29. Savulescu J, Cameron J, Wilkinson D. Equality or utility? Ethics and law of rationing ventilators. *Br J Anaesth.* 2020;125(1):10-5. <http://dx.doi.org/10.1016/j.bja.2020.04.011>. PMID:32381261.
30. Souza CDF, Paiva JPS, Leal TC, Silva LF, Santos LG. Evolução espaçotemporal da letalidade por Covid-19 no Brasil, 2020. *J Bras Pneumol.* 2020;46(4):56-8. PMID:32578681.
31. Pourghasemi HR, Pouyan S, Heidari B, Farajzadeh Z, Fallah Shamsi SR, Babaei S, et al. Spatial modeling, risk mapping, change detection, and outbreak trend analysis of coronavirus (Covid-19) in Iran (days between February 19 and June 14, 2020). *Int J Infect Dis.* 2020;98:90-108. <http://dx.doi.org/10.1016/j.ijid.2020.06.058>. PMID:32574693.
32. Adekunle IA, Onanuga AT, Akinola OO, Ogunbanjo OW. Modelling spatial variations of coronavirus disease (Covid-19) in Africa. *Sci Total Environ.* 2020;729:138998. <http://dx.doi.org/10.1016/j.scitotenv.2020.138998>. PMID:32361455.
33. Sannigrahi S, Pilla F, Basu B, Basu AS, Molter A. Examining the association between socio-demographic composition and Covid-19 fatalities in the European region using spatial regression approach. *Sustain Cities Soc.* 2020;62:102418. <http://dx.doi.org/10.1016/j.scs.2020.102418>. PMID:32834939.
34. Mollalo A, Vahedi B, Rivera KM. GIS-based spatial modeling of Covid-19 incidence rate in the continental United States. *Sci Total Environ.* 2020;728:138884. <http://dx.doi.org/10.1016/j.scitotenv.2020.138884>. PMID:32335404.
35. Cordes J, Castro MC. Spatial analysis of Covid-19 clusters and contextual factors in New York City. *Spat Spatio-Temporal Epidemiol.* 2020;34:1003555. <http://dx.doi.org/10.1016/j.sste.2020.100355>. PMID:32807400.
36. Demenech LM, Dumith SC, Vieira MECD, Neiva-Silva L. Desigualdade econômica e risco de infecção e morte por Covid-19 no Brasil. *Rev Bras Epidemiol.* 2020;23:e200095. <http://dx.doi.org/10.1590/1980-549720200095>.
37. Fortunato RA, Lima CA, Priori L. Covid-19 no Brasil: a evolução da doença num cenário de desigualdades sociais. *Middle Atl Rev Lat Am Stud.* 2020;4(1):26. <http://dx.doi.org/10.23870/marlas.310>.
38. Goes EF, Ramos DO, Ferreira AJF. Desigualdades raciais em saúde e a pandemia da Covid-19. *Trab Educ Saude.* 2020;18(3):e00278110. <http://dx.doi.org/10.1590/1981-7746-sol00278>.
39. Batista A, Antunes B, Faveret G, Peres I, Marchesi J, Cunha JP, et al. Nota Técnica 11 - 27/05/2020. Análise socioeconômica da taxa de letalidade da Covid-19 no Brasil [Internet]. Rio de Janeiro: NOIS; 2020 [citado em 2020 Ago 10]. Disponível em: <https://ponte.org/wp-content/uploads/2020/05/NT11-An%C3%A1lise-descritiva-dos-casos-de-COVID-19.pdf>
40. Natividade MDS, Bernardes K, Pereira M, Miranda SS, Bertoldo J, Teixeira MG, et al. Distanciamento social e condições de vida na pandemia Covid-19 em Salvador-Bahia, Brasil. *Cien Saude Colet.* 2020;25(9):3385-92. <http://dx.doi.org/10.1590/1413-81232020259.22142020>. PMID:32876242.