

**ANÁLISE ESPACIAL DA RELAÇÃO DOS CASOS E ÓBITOS DA COVID-19 COM INDICADORES SOCIOECONÔMICOS E DE SAÚDE NO MARANHÃO**

**SPATIAL ANALYSIS OF THE RELATIONSHIP OF COVID-19 CASES AND DEATHS WITH SOCIOECONOMIC AND HEALTH INDICATORS IN MARANHÃO**

**Larissa Karla Barros de Alencar**

Universidade Federal do Maranhão, MA, Brasil  
[larissa.kba@discente.ufma.br](mailto:larissa.kba@discente.ufma.br)

**Arlene de Jesus Mendes Caldas**

Universidade Federal do Maranhão, MA, Brasil  
[ajm.caldas@ufma.br](mailto:ajm.caldas@ufma.br)

**Thaís Furtado Ferreira**

Universidade Federal do Maranhão, MA, Brasil  
[thais.furtado@ufma.br](mailto:thais.furtado@ufma.br)

**Tereza Cristina Silva**

Instituto Federal do Maranhão, MA, Brasil  
[terezasilva@ifma.edu.br](mailto:terezasilva@ifma.edu.br)

**Larissa Neuza da Silva Nina**

Universidade Federal do Maranhão, MA, Brasil  
[larissa.nina@discente.ufma.br](mailto:larissa.nina@discente.ufma.br)

**Nair Portela Silva Coutinho**

Universidade Federal do Maranhão, MA, Brasil  
[nair.portela@ufma.br](mailto:nair.portela@ufma.br)

**Vanessa Moreira da Silva Soeiro**

Universidade Federal do Maranhão, MA, Brasil  
[moreira.vanessa@ufma.br](mailto:moreira.vanessa@ufma.br)

**RESUMO**

Objetivo: analisar a distribuição espacial dos casos e óbitos da COVID-19 e sua relação com indicadores socioeconômicos e de saúde do Maranhão, Brasil. Métodos: estudo ecológico, cuja unidade de análise foram os 217 municípios maranhenses. Estimaram-se incidência, mortalidade e letalidade por COVID-19, a partir de informações da Secretaria de Saúde do Estado até agosto de 2022. O Moran Global verificou autocorrelação espacial com incidência, mortalidade e letalidade, o Moran Local identificou *clusters* de alto e baixo risco. Resultados: a COVID-19 apresentou-se de forma heterogênea e não aleatória no estado do Maranhão, constatou-se autocorrelação espacial positiva da incidência, mortalidade e letalidade. As variáveis que melhor explicaram a ocorrência da COVID-19 foram o índice de Gini, IDHM, IVS, cobertura da Atenção Básica, proporção de pobres, aglomeração domiciliar e analfabetismo. Conclusão: os indicadores socioeconômicos e de saúde influenciaram a incidência, mortalidade e letalidade por COVID-19 no estado, devendo ser considerados na formulação de políticas públicas.

**Palavras-chave:** Epidemiologia. Análise espacial. Regressão espacial. COVID-19. Indicadores de saúde.

**ABSTRACT**

Objective: to analyze the spatial distribution of COVID-19 cases and deaths and their relationship with socioeconomic and health indicators in Maranhão. Methods: ecological study whose unit of analysis were 217 municipalities in Maranhão. Incidence, mortality, and lethality due to COVID-19 were estimated based on information from the State Health Department up to August 2022. Moran Global verified spatial autocorrelation with incidence, mortality, and lethality, Moran Local identified clusters of high and low risk. Results: COVID-19 took place in

a heterogeneous and non-random way in the state of Maranhão, positive spatial autocorrelation of incidence, mortality, and lethality was verified. The variables that best explained the occurrence of COVID-19 were the Gini index, HDI, IVS, primary care coverage, proportion of poor people, household crowding and illiteracy. Conclusion: socioeconomic and health indicators influenced the incidence, mortality, and lethality by COVID-19 in the state and should be considered in public policy formation.

**Keywords:** Epidemiology. Spatial analysis. Spatial regression. COVID-19. Health indicators.

## INTRODUÇÃO

A COVID-19 é uma doença infecciosa, altamente transmissível, causada pelo vírus SARS-CoV-2. Desde que foi relatada pela primeira vez na cidade de Wuhan, na China, no final de dezembro de 2019, o mundo acompanhou o crescimento exponencial do número de casos e óbitos pela doença. Devido à dimensão e gravidade, a Organização Mundial da Saúde (OMS) declarou, em 30 de janeiro de 2020, que o surto do coronavírus constituía emergência de saúde pública de importância internacional e, em 11 de março de 2020, caracterizou-a como uma pandemia (HUANG *et al.*, 2020; WHO, 2020a; OPAS, 2020).

Globalmente, até 27 de novembro de 2022, a COVID-19 acumulava o total de 637.737.550 casos e 6.611.874 óbitos. No Brasil, primeiro país da América do Sul a notificar casos da doença, de 26 de fevereiro de 2020, data da notificação do primeiro caso, a 26 de novembro de 2022, foram confirmados 35.163.004 casos e 689.468 óbitos da doença, destes, 479.305 (1,36%) casos e 11.004 (1,59%) óbitos ocorreram no Maranhão (BRASIL, 2022.; WHO, 2022)

A distribuição de COVID-19 ocorreu de forma heterogênea no país. As desigualdades socioeconômicas do Brasil foram cruciais para evolução da pandemia, áreas que apresentam maior vulnerabilidade socioeconômica foram desproporcionalmente mais afetadas pela doença (ROCHA *et al.*, 2021). Estudos realizados em estados brasileiros, constataram que variáveis socioeconômicas e de saúde estiveram relacionadas com a incidência, mortalidade e letalidade pela COVID-19, como o Índice de Gini, Índice de Vulnerabilidade Social - IVS, Índice de Desenvolvimento Humano Municipal - IDHM, taxa de pobreza, escolaridade, ocupação, condições de moradia, adensamento excessivo e cobertura da Atenção Básica (RAYMUNDO *et al.*, 2021; ROCHA *et al.*, 2021; VILLELA, 2021; MOREIRA, 2020; SOUZA, 2021).

Achados referentes à associação entre indicadores socioeconômicos e de saúde e os casos e óbitos por COVID-19 podem oferecer explicação plausível para as diferenças observadas na pandemia. Por ser um país de proporções continentais, o Brasil, cuja diversidade política, econômica, social e de saúde se expressa fortemente dentro dos limites geográficos, faz-se necessário compreender as particularidades dos estratos geográficos que interferem na ocorrência de casos e óbitos de COVID-19.

Pesquisas realizadas no estado do Maranhão descreveram a distribuição da COVID-19 (ALMEIDA *et al.*, 2020; LIRA *et al.*, 2020; SILVA *et al.*, 2022; OLIVEIRA JARDIM e PEREIRA, 2020; SILVA e RODRIGUES, 2022), no entanto, não buscaram identificar os fatores que podem estar relacionados a essa distribuição, bem como a correlação da doença com os indicadores socioeconômicos e/ou de saúde.

A caracterização da distribuição geográfica de agravos e os determinantes nas populações são elementos fundamentais para compreensão das doenças, sendo o geoprocessamento em saúde ferramenta útil, que permite realizar a associação dos casos e óbitos a variáveis. A abordagem espacial possibilita compreender melhor a distribuição, dinâmica e risco de doenças, especialmente de doenças transmissíveis, como a COVID-19 (CAVALCANTE; ABREU, 2020; MARTINES *et al.*, 2021).

É fundamental conhecer as características preditivas para ocorrência da doença, a fim de avaliar tendências futuras, bem como subsidiar a implantação de macropolíticas (saúde, educação, renda, infraestrutura). Deste modo, o presente estudo objetivou analisar a distribuição espacial dos casos e óbitos da COVID-19 e a relação com indicadores socioeconômicos e de saúde no estado do Maranhão, Brasil.

## MÉTODOS

Trata-se de estudo ecológico, cujas unidades de análise foram os 217 municípios do estado do Maranhão, estado brasileiro localizado na Região Nordeste. É um dos estados com menores índices (IDH), com 0,639 pontos, ocupando a penúltima posição no ranking brasileiro, além de possuir o maior Índice de Vulnerabilidade Social do país (IBGE 2020b; IBGE, 2021).

A população do estudo incluiu todos os casos e os óbitos de COVID-19 notificados no Maranhão, no período de março de 2020 a agosto de 2022.

Os dados referentes aos casos e óbitos da COVID-19 nos municípios foram extraídos do banco de dados disponibilizado pela Secretaria de Estado da Saúde. O quantitativo populacional de cada município, para cálculo das taxas de incidência e mortalidade, referente ao ano de 2021, foi extraído do site do Instituto Brasileiro de Geografia e Estatística (IBGE) e os indicadores socioeconômicos e de saúde foram obtidos dos dados disponíveis em sítios on-line do IBGE (IBGE, 2012), Instituto de Pesquisa Econômica Aplicada (IPEA, 2015) e e-Gestor Atenção Básica (BRASIL, 2020) (Quadro 1).

As variáveis dependentes utilizadas no presente estudo foram a incidência, mortalidade e letalidade da COVID-19. A taxa de incidência foi calculada pela razão entre o número de casos confirmados e a população, multiplicado por 100.000. A taxa de mortalidade foi calculada pela razão entre óbitos confirmados e a população, multiplicado por 100.000. A taxa de letalidade foi obtida pela razão entre o número de óbitos e o número de casos da doença, multiplicado por 100. As variáveis independentes utilizadas no presente estudo foram: população residente dos municípios do Maranhão, Índice de Gini, Índice de Desenvolvimento Humano Municipal (IDHM), Índice de Vulnerabilidade Social (IVS), proporção de pobres, aglomeração domiciliar, taxa de analfabetismo de pessoas com 15 anos ou mais e cobertura da Atenção Básica (AB) (Quadro 1).

Quadro 1 – Indicadores socioeconômicos e de saúde, definição e fonte dos dados

| Variáveis  | Definições   | Fontes e anos dos dados |
|--|--|-------------------------|
| População residente dos municípios do Maranhão   | Estimativa anual da população residente.   | IBGE/2010               |
| Índice de Gini   | Mede o grau de desigualdade existente na distribuição de indivíduos segundo a renda domiciliar per capita.   | IBGE/2010               |
| Índice de Desenvolvimento Humano Municipal   | Média geométrica dos índices das dimensões Renda, Educação e Longevidade, com pesos iguais.  | IBGE/2010               |
| Índice de Vulnerabilidade Social (IVS)   | Calculado a partir de média entre os subíndices: IVS infraestrutura urbana, IVS capital humano e IVS renda de trabalho.  | IPEA/2015               |
| Taxa de analfabetismo de pessoas com 15 anos ou mais   | Razão entre a população de 15 anos ou mais de idade que não sabe ler nem escrever um bilhete simples, e o total de pessoas nesta faixa etária multiplicada por 100.  | IBGE/2010               |
| Proporção de domicílios com rede geral de água   | Mede a cobertura de serviços, segundo domicílios, com abastecimento adequado de água à população, por meio de rede geral de distribuição.  | IBGE/2010               |
| Taxa de desocupação da população de 18 anos ou mais de idade                                       | Percentual da População Economicamente Ativa (PEA) nessa faixa etária que estava desocupada, ou seja, que não estava ocupada na semana anterior à data do censo, mas havia procurado trabalho ao longo do mês anterior à data da pesquisa. | IBGE/2010               |
| Proporção de população que vive em domicílios com densidade superior a duas pessoas por dormitório | Razão entre a população que vive em domicílios particulares permanentes com densidade superior a dois e a população total residente em domicílios particulares permanentes, multiplicada por 100.  | IBGE/2010               |

|                             |  |                     |
|-----------------------------|--|---------------------|
| Proporção de pobres         | Proporção dos indivíduos com renda domiciliar <i>per capita</i> igual ou inferior a R\$ 140,00 mensais, em reais de agosto de 2010.                    | IBGE/2010           |
| Renda per capita            | Renda média dos residentes de determinado município.   | IBGE/2010           |
| Cobertura da Atenção Básica | Número médio mensal de equipes da Atenção Básica à saúde, para cada 3.000 pessoas, em relação à população total residente no município e ano avaliado. | E-Gestor AB – 2020* |

\*E-Gestor AB (BRASIL, 2020).  
Fonte: IBGE, 2012; BRASIL, 2020.

Após captação, os dados foram transferidos para planilha do *Microsoft Excel*, em que foi realizada a limpeza do banco de dados e, posteriormente, realizada a análise estatística descritiva utilizando-se o software STATA®, versão 16, onde foram estimadas a taxas de incidência, mortalidade e letalidade por COVID-19.

Utilizou-se do Índice de Moran Global (I) para verificar a existência da autocorrelação espacial dos casos e óbitos de COVID-19, com a incidência, mortalidade e letalidade por COVID-19. O valor calculado do Moran Global (I) varia de -1 a +1. Confirmou-se a correlação direta quando o valor foi positivo; correlação inversa, quando negativo; e ausência da autocorrelação espacial, quando o valor foi igual a zero (CÂMARA *et al.*, 2004). O Índice de Moran Global foi avaliado pela pseudosignificância, com 999 permutações, e considerado estatisticamente significativo o valor de  $p < 0,05$ .

Criou-se a Matriz de Proximidade (Matriz de Vizinhança) entre os 217 municípios do estado, definido pelo método de fronteira (municípios vizinhos). Neste estudo, adotou-se a matriz de vizinhança Queen de 1ª ordem, pois gerou o maior valor do Índice Global de Moran.

Para identificação das áreas de alto e baixo risco (*clusters*), o Índice de Moran Local foi usado para detectar regiões com autocorrelação espacial significativa ( $p < 0,05$ ). Municípios com alta incidência, mortalidade e letalidade por COVID-19 e que eram rodeados por município que também apresentavam estes indicadores elevados (padrão de autocorrelação chamado de Alto-Alto) foram considerados clusters de Alto Risco. De modo semelhante, municípios com baixa incidência, mortalidade e letalidade, que eram rodeados por municípios que também apresentavam baixos indicadores (padrão de autocorrelação Baixo-Baixo), foram considerados como clusters de Baixo Risco. Os municípios com padrão de autocorrelação Baixo-Alto e Alto-Baixo não foram considerados clusters, mas áreas de transição (CÂMARA *et al.*, 2004).

Ao constatar a autocorrelação espacial, construiu-se a matriz de correlação de *Spearman* (em virtude da ausência de distribuição normal das variáveis). As variáveis explicativas correlacionadas estatisticamente a 5% com as variáveis dependentes foram elegíveis para compor os modelos de regressão clássica e espacial. Utilizou-se, ainda, do método *stepwise* para seleção e observância das variáveis não colineares (*variance inflation factor*,  $VIF < 0,7$ ).

Posteriormente, aplicou-se o modelo de regressão linear múltipla, *Ordinary Least Squares Estimation* (OLS), seguido dos modelos espaciais globais. O modelo espacial autoregressivo (*Spatial Lag Model*), o primeiro a ser utilizado, atribui à variável resposta Y a autocorrelação espacial ignorada. O segundo modelo foi o erro espacial (*Spatial Error Model*), que considerou os efeitos espaciais como um ruído, isto é, como fator a ser removido.

A escolha do modelo que melhor se ajustou às variáveis deu-se pela observância do maior valor de Log de Verossimilhança e menores valores do critério de informação de *Akaike* (AIC) e do critério bayesiano *Schwarz*. Os resíduos nos modelos *Spatial Lag* e *Spatial Error* foram analisados pelo Índice de Moran I para verificar quantitativamente se a autocorrelação espacial foi eliminada (ANSELIN, 2005).

Os mapas temáticos da distribuição da incidência, letalidade e mortalidade por município foram confeccionados por meio do software QGIS, versão 3.12.0, com base na malha digital do Maranhão, a partir da base cartográfica do IBGE. Para o cálculo dos índices de autocorrelação espacial global, assim como os modelos regressivos, foi usado o software GeoDa, versão 1.14.

No que diz respeito aos aspectos éticos, o estudo faz parte da pesquisa intitulada “Dinâmica Espacial da COVID-19: análise dos casos, óbitos e da oferta de leitos no Maranhão”, aprovada pelo CEP-HU-

UFMA, conforme parecer nº 4.354.709/2020, atendendo às Resoluções 466/12 e 510/2016 do Conselho Nacional de Saúde (CNS).

## RESULTADOS

De 20 de março de 2020, data do primeiro caso confirmado de COVID-19 no Maranhão, a 31 de agosto de 2022, foram notificados neste estado 468.943 casos e 11.524 óbitos por COVID-19. Os municípios com maior número de casos foram: São Luís, Imperatriz e Caxias, com 73.218 (15,61%), 26.423 (5,68%) e 17.679 (3,76%), respectivamente. Dos 217 municípios do estado, Boa Vista do Gurupi foi o que registrou o menor número (16 casos), correspondendo a 0,0034%.

Em relação aos óbitos, São Luís notificou o maior percentual (24,93%), seguido de Imperatriz (8,44%) e São José de Ribamar (3,34%). Apenas o município de São Francisco do Brejão não registrou óbito pela COVID-19. Os municípios de Santa Filomena do Maranhão, Milagres do Maranhão, Presidente Juscelino, Senador Alexandre Costa e Governador Luiz Rocha notificaram somente um óbito cada (Figura 1).

Quanto à incidência, a maior taxa foi registrada no município Lagoa do Mato (25.957,44/100 mil hab.), seguida de Feira Nova do Maranhão (18.927,81/100 mil hab.), Balsas (17.102,45/100 mil hab.), Igarapé Grande (16.964,98/100 mil hab.) e Pedreiras (16.612,86/100 mil hab.), e a menor taxa foi no município de Boa Vista do Gurupi (188,36/100 mil hab.) (Figura 1).

Os municípios que apresentaram maiores taxas de mortalidade foram Imperatriz (374,25/100mil hab.), Campestre do Maranhão (330,35/100 mil hab.) e Porto Franco (304,60/100 mil hab.). Em relação à taxa de letalidade, destacaram-se os municípios de Boa Vista do Gurupi (31,25%), Pedro do Rosário (8,74%) e Senador La Roche (7,79%) (Figura 1).

A dispersão da COVID-19 no Maranhão ocorreu de forma heterogênea, porém, não aleatória. O Índice de Moran I apontou autocorrelação espacial positiva para incidência, mortalidade e letalidade no período, com valor de 0,322, 0,353 e 0,058, respectivamente, sendo possível identificar aglomerados de alto risco (*cluster* alto-alto) e baixo risco (*cluster* baixo-baixo) para as variáveis dependentes analisadas (Figura 2).

O cluster de alto risco para incidência foi formado por 28 municípios, doze destes encontram-se localizados na mesorregião centro, três municípios na região leste e 13 municípios na região sul. O de baixo risco foi formado por 25 municípios distribuídos nas mesorregiões oeste, norte e leste do estado (Figura 2).

Quanto ao cluster de alto risco para mortalidade, o maior aglomerado, formado por 19 municípios, encontra-se nas mesorregiões leste, centro e sul maranhense, além de mais seis municípios distribuídos na mesorregião norte, centro e sul (Figura 2).

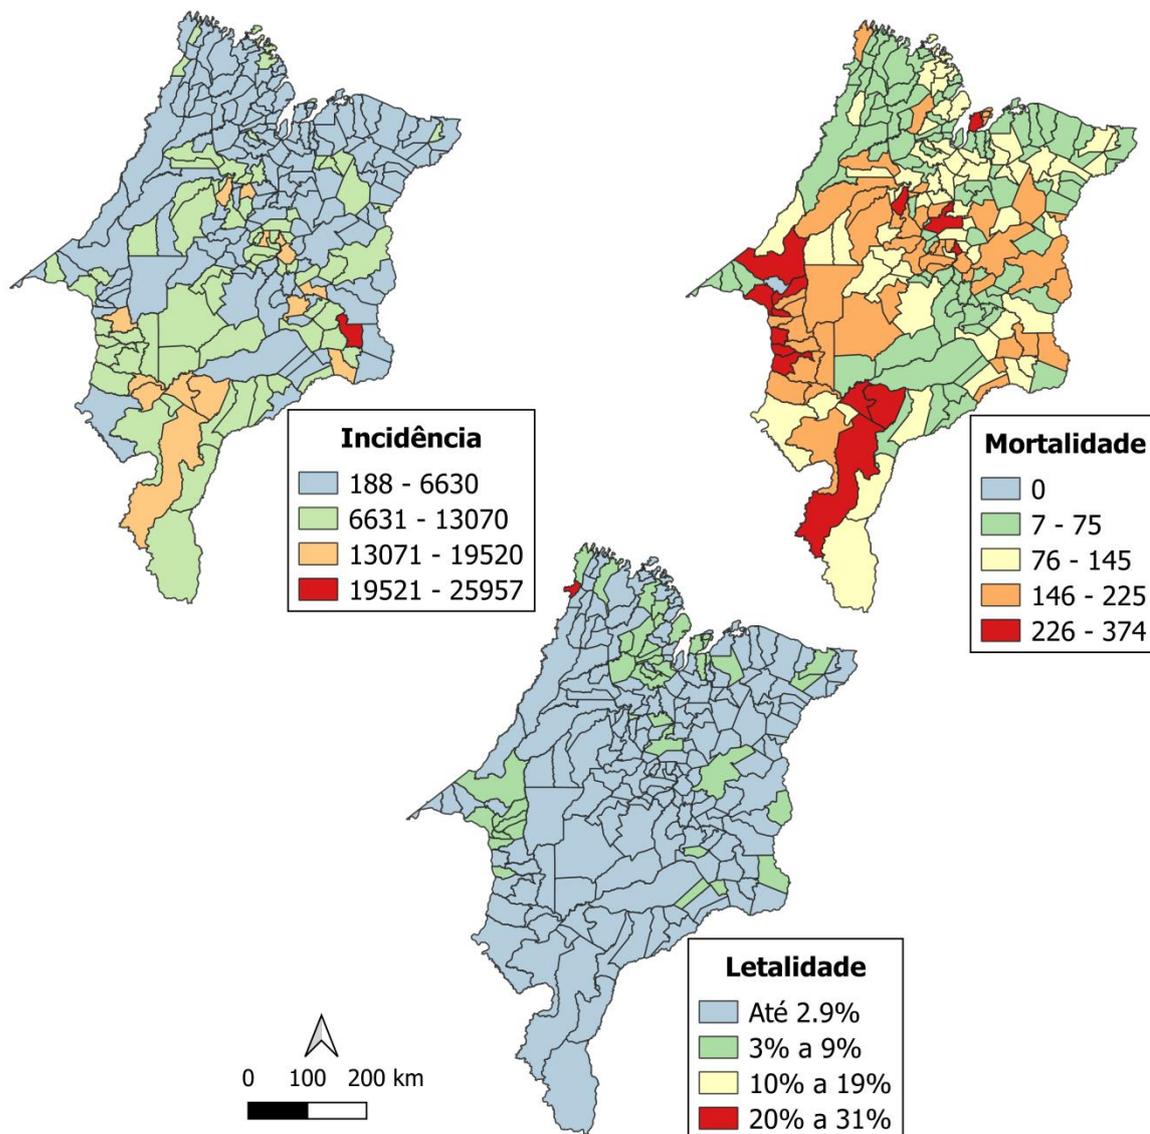
Vinte e dois municípios formaram o cluster de baixo risco para mortalidade, distribuídos em quatro das cinco mesorregiões do estado (oeste, norte, centro e leste maranhense). Destaca-se que dois desses municípios encontram-se isolados, Viana e São Félix de Balsas (Figura 2).

Quanto à formação do aglomerado de alto risco para letalidade por COVID-19 nos municípios maranhenses, identificaram-se 12 municípios, distribuídos nas mesorregiões oeste e norte do estado. De forma isolada, encontravam-se os municípios de Carutapera, Presidente Sarney e São Vicente Ferrer (Figura 2).

Compuseram o cluster de baixo risco para letalidade por COVID-19 12 municípios localizados nas mesorregiões centro, leste e sul do estado, destacando-se um município na região norte, Apicum-Açu (Figura 2).

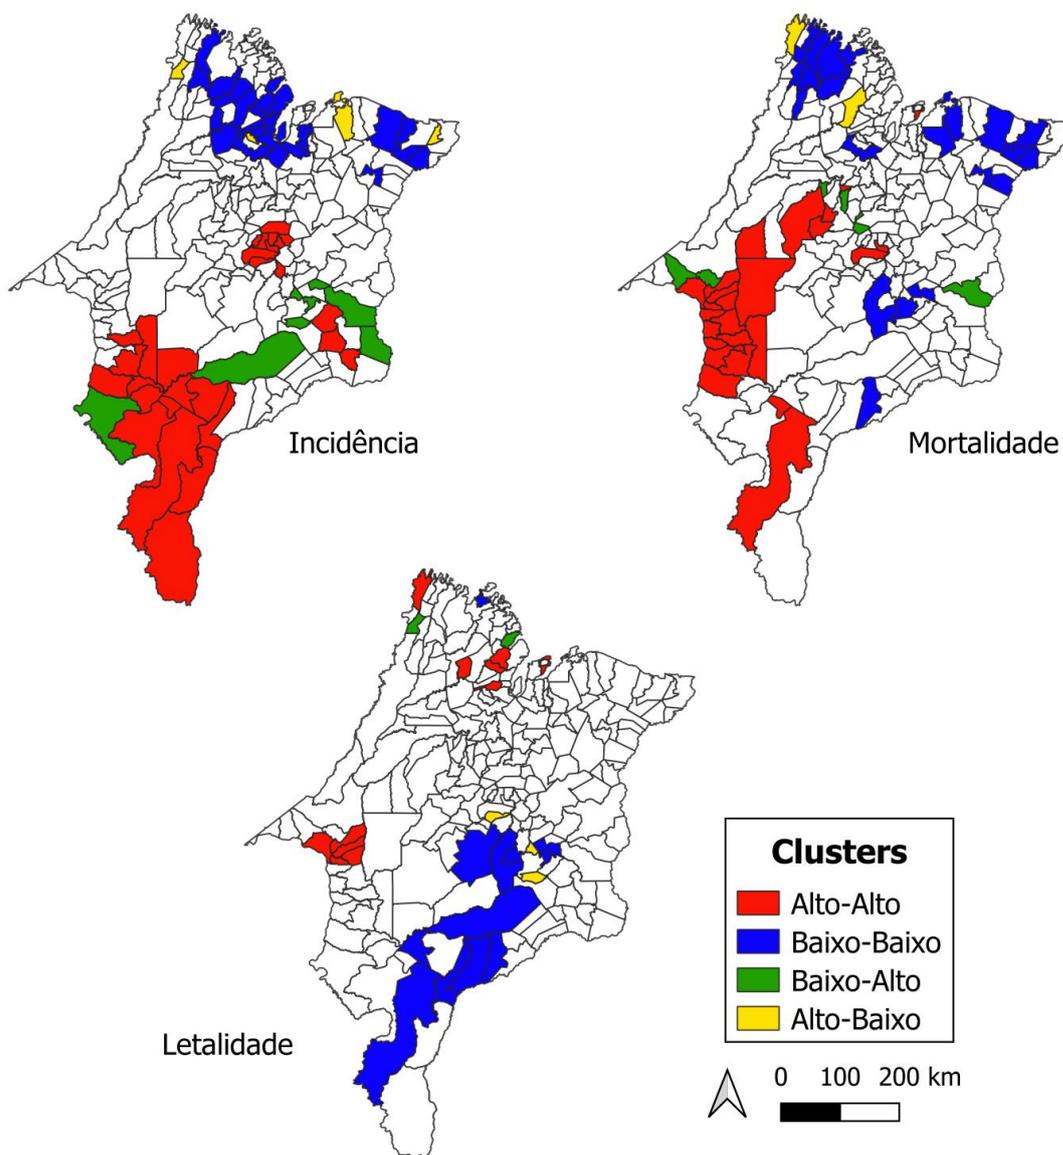
Quanto à sobreposição de clusters, observou-se que sete municípios (Balsas, Bernardo do Mearim, Estreito, Nova Colinas, Poção de Pedras, São João do Paraíso e Sítio Novo) compuseram tanto os clusters de alto risco para incidência quanto alto risco para mortalidade (Figura 2). Buritirana, Davinópolis, Imperatriz, João Lisboa e Senador La Rocque apresentaram alto risco para mortalidade e letalidade (Figura 2).

Figura 1 – Distribuição espacial das taxas de incidência e mortalidade (por 100.000 habitantes) e letalidade (por 100) da COVID-19 no Maranhão, 2022



Fonte: Os autores, com base nos dados da pesquisa.

Figura 2 – Clusters da incidência e mortalidade (por 100.000 habitantes) e letalidade (por 100) da COVID-19 no Maranhão, 2022



Fonte: Os autores, com base nos dados da pesquisa.

Ao avaliar a autocorrelação entre a incidência, mortalidade e letalidade pela COVID-19 e as onze variáveis independentes, o modelo OLS constatou autocorrelação espacial com sete variáveis dependentes.

O modelo *Spatial Lag* foi o que melhor se ajustou à variável incidência, com maior poder explicativo ( $R^2 = 0,299$ ), e menores AIC e SBC. O modelo *Spatial Error* apresentou melhor desempenho para as variáveis mortalidade ( $R^2 = 0,586$ ) e letalidade ( $R^2 = 0,0948$ ) (Tabela 1).

Tabela 1 – Comparação dos modelos de regressão a partir do R<sup>2</sup>, log da verossimilhança, critério de informação de Akaike, critério bayesiano Schwarz e índice de Moran global dos resíduos

| ParâmetroS                       | OLS <sup>a</sup> | <i>Spatial Lag</i> <sup>b</sup> | <i>Spatial error</i> <sup>c</sup> |
|----------------------------------|------------------|---------------------------------|-----------------------------------|
| <b>Incidência</b>                |                  |                                 |                                   |
| R <sup>2d</sup>                  | 0,223            | 0.299                           | 0.292                             |
| Log da verossimilhança           | -2078.24         | -2071.59                        | -2073.09                          |
| Critério de informação de Akaike | 4168.48          | 4157.19                         | 4158.19                           |
| Critério bayesiano Schwarz       | 4188.76          | 4180.85                         | 4181.47                           |
| Moran Global dos resíduos        | 0.1358           | -0.031                          | -0.034                            |
| <b>Mortalidade</b>               |                  |                                 |                                   |
| R <sup>2d</sup>                  | 0.464            | 0.537                           | 0.586                             |
| Log da verossimilhança           | -1159.88         | -1149                           | -1141.21                          |
| Critério de informação de Akaike | 2331.76          | 2312                            | 2294.44                           |
| Critério bayesiano Schwarz       | 2352.04          | 2335.66                         | 2314.72                           |
| Moran Global dos resíduos        | 0.2889           | 0.086                           | -0.011                            |
| <b>Letalidade</b>                |                  |                                 |                                   |
| R <sup>2d</sup>                  | 0.0946           | 0.0966                          | 0.0948                            |
| Log da verossimilhança           | -491.72          | -491.56                         | -490.70                           |
| Critério de informação de Akaike | 995.444          | 997.13                          | 995.41                            |
| Critério bayesiano Schwarz       | 1015.72          | 1020.79                         | 1015.69                           |
| Moran Global dos resíduos        | 0.0067           | -0.015                          | -0.000                            |

<sup>a</sup> OLS: ordinary least squares estimation, regressão linear múltipla.

<sup>b</sup> Spatial lag: modelo espacial autorregressivo que atribui à variável dependente Y a autocorrelação espacial ignorada.

<sup>c</sup> Spatial error: modelo de erro espacial, que considera os efeitos espaciais como um ruído ou fator a ser removido.

<sup>d</sup> R<sup>2</sup>: poder explicativo.

Fonte: Os autores, com base nos dados da pesquisa.

As variáveis que melhor explicaram a incidência pelo modelo *Spatial Lag* foram a cobertura da atenção básica, Índice de Gini, proporção de pobres, IDHM e IVS. Em relação à mortalidade, as variáveis proporção de pobres, IVS, Índice de Gini e taxa de analfabetismo de pessoas maiores de 15 anos ou mais apresentaram-se estatisticamente significativas. Para letalidade, constatou-se significância estatística para as variáveis cobertura da atenção básica, proporção de população que vive em domicílios com densidade superior a duas pessoas por dormitório e taxa de analfabetismo de pessoas com 15 anos ou mais (Tabela 2).

O Índice global de Moran dos resíduos do *Spatial Lag* para incidência foi de -0,031 ( $p < 0,001$ ), -0,011 do *Spatial Error* para mortalidade e -0,000 para letalidade, indicando que a inclusão do componente espacial eliminou a autocorrelação espacial dos resíduos (valor mais próximo de zero), especialmente quando comparado aos resíduos da OLS (Tabelas 1 e 2).

Tabela 2 – Modelo final da regressão para incidência, mortalidade e letalidade por COVID-19 nos municípios maranhenses

|                                    | Coeficiente     | Erro-padrão | P-valor |
|------------------------------------|-----------------|-------------|---------|
| <b>Incidência – Spatial Lag</b>    |                 |             |         |
| Cobertura da atenção básica        | 50.2055         | 23.4286     | 0.03    |
| Gini                               | 18088.3         | 5732.19     | 0.001   |
| Proporção de Pobres                | -158.198        | 47.081      | <0.001  |
| IDHM                               | -27874.3        | 10896.3     | 0.01    |
| IVS                                | -10025.6        | 3571.05     | 0.004   |
| <b>Mortalidade – Spatial Error</b> |                 |             |         |
| Proporção de Pobres                | -3.37545        | 0.551099    | <0.001  |
| Gini                               | 179.746         | 74.2513     | 0.015   |
| % analfabetismo > 15 anos          | 1.66075         | 0.872165    | 0.05    |
| Hygeia                             | Uberlândia - MG | v. 20       | 2024    |
|                                    |                 | e2023       | 8       |

|                                   |            |           |        |
|-----------------------------------|------------|-----------|--------|
| IVS <sup>b</sup>                  | -238.513   | 50.0595   | <0.001 |
| <b>Letalidade - Spatial Error</b> |            |           |        |
| Cobertura da atenção básica       | -0.0451276 | 0.0161493 | 0.005  |
| % densidade > 2 <sup>a</sup>      | 0.0436497  | 0.0216818 | 0.044  |
| % analfabetismo > 15 anos         | -0.0552667 | 0.0254141 | 0.029  |

<sup>a</sup> Percentual da população que vive em domicílios com densidade superior a duas pessoas por dormitório.

<sup>b</sup> Índice de Vulnerabilidade Social.

Fonte: Os autores, com base nos dados da pesquisa.

## DISCUSSÃO

O presente estudo analisou a distribuição espacial das taxas de incidência, mortalidade e letalidade da COVID-19, que foram bastante distintas, com ampla variação entre os municípios maranhenses, evidenciando grande heterogeneidade. Entretanto, a distribuição da COVID-19 não ocorreu de forma aleatória, apresentando autocorrelação espacial positiva, sendo possível identificar regiões de alto e baixo risco, além de demonstrar correlação das variáveis explicativas, indicadores socioeconômicos e de saúde, com evolução da pandemia no Maranhão.

O maior número de casos da COVID-19 esteve concentrado entres os municípios mais populosos, São Luís, capital do estado, seguido de Imperatriz, Caxias. Esses municípios compõem as principais regionais urbanas do estado, concentrando intenso fluxo econômico, de mercadorias e serviços médico-hospitalares, gerando dependência dos demais municípios, provocando o deslocamento de pessoas em busca desses serviços, favorecendo o fluxo de pessoas e, conseqüentemente, propiciando a elevação do número de casos e mortalidade (OLIVEIRA, GONÇALVES, PAZ, 2021).

Oliveira Jardim e Pereira (2020) mapearam as áreas de transmissão da COVID-19 no Maranhão, evidenciando que a disseminação da doença iniciou em áreas nobres da capital do estado (Renascença, Calhau e Turu), porém os níveis de transmissão foram mais acelerados nos bairros periféricos, como Coroadinho, Cidade Operária, Habitacional do São Raimundo, sugerindo que a pandemia iniciou em regiões com melhores condições socioeconômicas e se expandiu para áreas mais vulneráveis (CESTARI *et al.*, 2021, LIRA *et al.*, 2020), corroborando os achados deste estudo.

Na busca pela compreensão dos fatores que se relacionam com a COVID-19, analisou-se a autocorrelação entre a incidência, mortalidade e letalidade com as variáveis socioeconômicas e de saúde. A constatação de dependência espacial auxiliou na compreensão da ocorrência da COVID-19 no estado, comprovada pelo aumento do poder explicativo das variáveis inseridas no modelo e dos Índices de Moran global e local. Nas análises realizadas, os indicadores socioeconômicos e de saúde estiveram correlacionados espacialmente não apenas à disseminação da COVID-19, como também à mortalidade e letalidade.

Estudos realizados revelam que, no Brasil, a disseminação da infecção e das mortes pela COVID-19 foi mais afetada por padrões de vulnerabilidade socioeconômica, desigualdades socioeconômicas, que por idade, estado de saúde e outros fatores de risco, com carga desproporcional para estados e municípios com alta vulnerabilidade socioeconômica (ROCHA *et al.*, 2021).

O Índice de Gini relacionou-se com a incidência e a mortalidade por COVID-19 nos municípios maranhenses. Estudos de abrangência nacional e internacional encontraram resultados semelhantes. Barbosa *et al.* (2022) analisaram dados de 185 países e Demenech *et al.* (2020) dos estados brasileiros, ambos identificaram correlação positiva da taxa de incidência e mortalidade com o Índice de Gini, inferindo que quanto maior a desigualdade econômica, maior a taxa de incidência e mortalidade pela COVID-19.

Apesar da COVID-19 poder afetar qualquer pessoa que se exponha ao vírus, as desigualdades econômicas podem contribuir para disseminação mais rápida das doenças infecciosas, pois estas impedem que o acesso aos serviços de saúde e leitos hospitalares ocorra de forma democrática, resultando em impacto negativos para populações em desvantagem econômica (HAMIDI; SABOURI; EWIND, 2020).

Neste estudo, os municípios com piores IDHM apresentaram maior incidência pela COVID-19. Estes achados estão em consonância com estudo realizado nos municípios com maior incidência do Ceará,

sendo os de menor IDHM os que apresentaram maior incidência da doença (SILVA *et al.* 2023a). Realizado, também, no Ceará, outro estudo, encontrou resultado divergente, associação positiva na relação do IDHM e incidência no estado, sendo importante ressaltar que esse estudo foi realizado nos meses iniciais da pandemia (MACIEL; CASTRO-SILVA; FARIAS, 2020). Municípios que apresentam populações mais vulneráveis têm mais dificuldade em manter medidas de proteção adequadas e aderirem às medidas de distanciamento social e menos acesso a serviços de saúde, além de utilizarem mais o transporte público, aumentando o risco significativo para propagação viral (CAVALCANTE FILHO *et al.*, 2022, SOUZA, MACHADO, CARMO, 2020; SILVA *et al.*, 2022).

Em relação ao IVS, os resultados do presente estudo apontam que o índice foi inversamente proporcional à incidência e mortalidade pela COVID-19. Outro ponto analisado foi a correlação da proporção de pobres com as taxas de incidência e mortalidade da COVID-19. Neste estudo, os municípios com menor proporção de pobres apresentaram maiores taxas de incidência e mortalidade pela COVID-19.

Estudo realizado em Sergipe encontrou resultado semelhante, municípios menos vulneráveis socialmente apresentaram maior taxa de incidência, inferindo-se que municípios menos vulneráveis realizaram maior quantidade de testes diagnóstico para COVID-19 e, possivelmente, a maior incidência está relacionada a este fator (CAVALCANTE FILHO, 2022). Outro estudo realizado em Natal (Rio Grande do Norte) revelou correlação forte e significativa da taxa de incidência à renda média *per capita*, demonstrando que quanto maior a renda, maior as taxas de incidência (TEIXEIRA *et al.*, 2020).

A associação da variável taxa de analfabetismo com a mortalidade mostrou que municípios com maior taxa de analfabetos apresentaram maior mortalidade por COVID-19, condizente ao encontrado no estudo realizado por Wollenstein-Betech *et al.* (2020) que constataram associação significativa entre a baixa escolaridade, particularmente nos analfabetos, e aumento da taxa de mortalidade.

O analfabetismo pode afetar a capacidade de compressão sobre doenças, dificuldade de seguir as recomendações relacionadas à prevenção, além de que pessoas com menor nível de escolaridade enfrentaram barreiras adicionais para acessar informações e serviços de saúde (BARBOSA *et al.*, 2022). Essas barreiras podem resultar em atraso no tratamento, acarretando aumento do risco de transmissão e gravidade e, conseqüentemente, da mortalidade e letalidade por COVID-19.

Ao considerar a variável cobertura da atenção básica, municípios com maiores coberturas estiveram relacionados com maior incidência, pior cobertura esteve relacionada com maior letalidade por COVID-19. Estudo ecológico realizado no Estado de Santa Catarina evidenciou resultados semelhantes ao presente estudo, em que as taxas de mortalidade e letalidade foram significativamente menores em municípios com maior cobertura da atenção básica (SOUZA *et al.*, 2021). Salienta-se que regiões com melhores recursos de serviços de saúde, principalmente a atenção básica, porta de entrada do SUS, tiveram acesso à testagem para a doença, sendo possível realizar o diagnóstico e tratamento precoce. Assim, regiões com melhores coberturas de atenção básica apresentam maior incidência da COVID-19 e menor letalidade (FIGUEIREDO *et al.*, 2020a).

Pode-se citar o município de Boa Vista do Gurupi, com destaque em relação à letalidade. Apesar do município apresentar o menor número de casos de COVID-19 do estado, apenas 16, apresenta a maior taxa de letalidade, 31,25%, com total de cinco óbitos. A baixa cobertura da AB pode ser um dos fatores relacionados à alta letalidade, já que Boa Vista do Gurupi ocupa o ranking dos 10 municípios com piores cobertura da AB.

Em relação à aglomeração domiciliar, houve associação positivamente com a letalidade. Enfatiza-se que populações mais pobres sofrem com piores condições de moradias e saneamento básico, que faz com que muitas pessoas tenham que conviver em ambientes de pouco espaço, favorecendo a disseminação de doenças, incluindo a COVID-19 (DOS SANTOS *et al.*, 2022). Habitar em domicílios com condições inadequadas é fator de risco para infecções respiratórias, além de apresentar maior possibilidade de desenvolver complicações graves (FIGUEIREDO *et al.*, 2020b).

Destaca-se que muitos estudos utilizados nesta discussão foram realizados utilizando-se de dados do início da pandemia, quando os casos e óbitos estavam em ascensão. Somado a isto, o desconhecimento da doença, a indisponibilidade e dificuldade de acesso aos testes podem ter subestimado os valores reais da COVID-19.

Como limitações, elencam-se a utilização de bases de dados secundários, passíveis de inconsistências (subnotificação dos casos, presença de dados ignorados ou incompletos), uso de variáveis censitárias de 2010, que podem não corresponder à realidade atual, e não inclusão das flutuações ocorridas no período, a exemplo das variantes virais e da cobertura vacinal. Como ponto forte, destaca-se a utilização de todos os dados notificados da COVID-19 no período estudado, a análise de regressão espacial, por conferir robustez aos resultados, o que permitiu a análise situacional da pandemia no Maranhão.

## CONCLUSÃO

A distribuição espacial das taxas de incidência, mortalidade e letalidade da COVID-19 apresentou-se de forma heterogênea, não aleatória, com autocorrelação espacial positiva, permitindo identificação de áreas prioritárias localizadas nas regiões central e sul do Maranhão, bem como demonstrou correlação dos indicadores socioeconômicos e de saúde com a evolução da pandemia no estado.

Assim, espera-se que os resultados possam contribuir para planejamento de ações em saúde e definição de um plano estadual de gestão mais próximo da realidade epidemiológica e social do estado. E, para pesquisas futuras, sugere-se a inclusão de recortes tempo-espaciais diferenciados e de outras variáveis que possam explicar a situação da COVID-19 no Maranhão.

## FINANCIAMENTO

Este trabalho foi financiado pela Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico e Tecnológico do Maranhão (FAPEMA), além do apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001.

## REFERÊNCIAS

- ALMEIDA, J. dos S.; CARDOSO, J. A.; CORDEIRO, E. C.; LEMOS, M.; ARAÚJO, T. M. E. de; SARDINHA, A. H. de L. Epidemiological characterization of COVID-19 cases in Maranhão: a brief analysis. **Revista Prevenção de Infecção e Saúde**, v. 6, 2020. <https://doi.org/10.26694/repis.v6i0.10477>
- ANSELIN, L. Exploring Spatial Data with GeoDaTM: A Workbook. **Centre for Spatially Integrated Social Science**. 2005. Disponível em: <http://geodacenter.asu.edu/software/downloads>. Acesso em: 15 set. 2021.
- BARBOSA, S. de P.; PAULA, P. A. B. de; AMORIM, M. M. A. de; PEREIRA, L. S. da S.; REIS, Y. P. Letramento em saúde como estratégia de promoção da saúde: um estudo de revisão narrativa. **Conjecturas**, v. 22, n. 7, p. 211–233, 2022. <https://doi.org/10.53660/CONJ-S30-1155>
- BRASIL. Ministério da Saúde. Secretaria de Atenção Primária à Saúde. e-Gestor AB - Informação e Gestão da Atenção Básica. **Cobertura da Atenção Básica**. 2020. <https://doi.org/10.51723/ccs.v30i02.409>
- BRASIL. Ministério da Saúde. **Boletins Epidemiológicos da COVID-19**. Brasília (DF): Ministério da Saúde, 2022. <https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/boletins/epidemiologicos/COVID-19/2022/boletim-epidemiologico-no-141-boletim-coe-coronavirus/view>. Acesso em: 10 dez. 2022.
- CÂMARA, G.; DRUCK, S.; CARVALHO, M. S.; MONTEIRO, A. M. V. Análise espacial de áreas. In: DRUCK, S. *et al.* **Análise espacial de dados geográficos**. Brasília (DF): EMBRAPA, 2004.
- CAVALCANTE, J. R.; ABREU, A. de J. L. de COVID-19 no município do Rio de Janeiro: análise espacial da ocorrência dos primeiros casos e óbitos confirmados. **Epidemiologia e Serviços de Saúde**, v. 29, n. 3, p. e2020204, 2020. <https://doi.org/10.5123/S1679-49742020000300007>
- CAVALCANTE FILHO, J. B. C.; OLIVEIRA, R. M. de; CHAGAS, R. D. O.; GÓES, M. A. de O; PEIXOTO, M. V. da S.; NUNES, M. A. P. A Pandemia de COVID-19 e Iniquidades em Saúde no Estado de Sergipe: **O Mundo da Saúde**, v. 46, p. 301–310, 2022. <https://doi.org/10.15343/0104-7809.202246301310>
- DEMENECH, L. M.; DUMITH, S. de C.; VIEIRA, M. E. C. D.; & NEIVA-SILVA, L. Desigualdade econômica e risco de infecção e morte por COVID-19 no Brasil. **Revista Brasileira de Epidemiologia**, v. 23, p. e200095, 2020. <https://doi.org/10.1590/1980-549720200095>

- FIGUEIREDO, A. M. de; FIGUEIREDO, D. C. M. M. de; GOMES, L. B.; MASSUDA, A.; GIL-GARCIA, E.; VIANNA, R. P. de T.; DAPONTE, A. Social determinants of health and COVID-19 infection in Brazil: an analysis of the pandemic. **Revista Brasileira de Enfermagem**, v. 73, n. suppl 2, p. e20200673, 2020. <https://doi.org/10.1590/0034-7167-2020-0673>
- HAMIDI, S.; SABOURI, S.; EWING, R. Does Density Aggravate the COVID-19 Pandemic? **Journal of the American Planning Association**, v. 86, n. 4, p. 495–509, 2020. <https://doi.org/10.1080/01944363.2020.1777891>
- HUANG, C.; WANG, Y.; LI, X.; REN, L.; ZHAO, J.; HU, Y.; ZHANG, L.; FAN, G.; XU, J.; GU, X.; CHENG, Z.; YU, T.; XIA, J.; WEI, Y. WU, W.; X, X.; Y, W; Y., LI, H.; LIU, M.; XIAO, Y. GAO, H.; GUO, LI; XIE, J. WANG, G.; JIANG, R.; GAO, Z.; JIN, OI; WANG, J.; CAO, B. Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. **The lancet**, v. 395, n. 10223, p. 497-506, 2020. [https://doi.org/10.1016/S0140-6736\(20\)30183-5](https://doi.org/10.1016/S0140-6736(20)30183-5)
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo 2010**. Rio de Janeiro: IBGE, 2012. Disponível em: <http://censo2010.ibge.gov.br/>. Acesso em: dez. 2022.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Coordenação de População e Indicadores Sociais. **Síntese de indicadores sociais: uma análise das condições de vida da população brasileira**: Rio de Janeiro: IBGE, 2020b. (Estudos e Pesquisas. Informação Demográfica e Socioeconômica; 43).
- INSTITUTO DE PESQUISA ECONÔMICA APLICADA - IPEA. **Atlas da Vulnerabilidade Social nos Municípios Brasileiros**. Ipea. 2015.
- LIRA, G. B. dos S.; SANTOS, G. G. dos; ALVES, M. E. M.; NERIS, J. P. F.; FREITAS, T. P. M. de. **Geotecnologias como ferramenta de estudo em saúde pública: uma análise espacial sobre a dispersão da COVID-19 no estado do Maranhão**. <https://doi.org/10.31692/IICOINTERPDVS.0059>
- MACIEL, J. A. C.; CASTRO-SILVA, I. I.; FARIAS, M. R. de. Análise inicial da correlação espacial entre a incidência de COVID-19 e o desenvolvimento humano nos municípios do estado do Ceará no Brasil. **Revista Brasileira de Epidemiologia**, v. 23, p. e200057, 2020. <https://doi.org/10.1590/1980-549720200057>
- MARTINES, M. R.; FERREIRA, R. V.; TOPPA, R. H.; ASSUNÇÃO, L. M.; DESJARDINS, M. R.; DELMELLE, E. M. Detecting space–time clusters of COVID-19 in Brazil: mortality, inequality, socioeconomic vulnerability, and the relative risk of the disease in Brazilian municipalities. **Journal of Geographical Systems**, v. 23, p. 7-36, 2021. <https://doi.org/10.1007/s10109-020-00344-0>
- MOREIRA, R. S. COVID-19: unidades de terapia intensiva, ventiladores mecânicos e perfis latentes de mortalidade associados à letalidade no Brasil. **Cadernos de Saúde Pública**, v. 36, p. e00080020, 2020. <https://doi.org/10.1590/0102-311x00080020>
- OLIVEIRA JARDIM, R.; PEREIRA, C. R. P. Pandemia do coronavírus (COVID-19): análise da evolução de casos frente à disponibilidade de leitos no estado do Maranhão, Brasil, 2020. **Ensaios de Geografia**, v. 5, n. 9, p. 40-46, 29 maio 2020. Disponível em: [https://periodicos.uff.br/ensaios\\_posgeo/article/view/42508](https://periodicos.uff.br/ensaios_posgeo/article/view/42508). Acesso em: 16 set. 2021.
- OLIVEIRA, A. B.; FERREIRA LOPES GONÇALVES, L.; ARMANDO DE SOUSA PAZ, D. Particularidades regionais da difusão e atendimento do paciente com COVID-19 na rede urbana da cidade de São Luís, Maranhão, Brasil. **Ateliê Geográfico**, Goiânia, v. 15, n. 1, p. 170–193, 2021. <https://doi.org/10.5216/ag.v15i1.65495>
- ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE. **Histórico da pandemia de COVID-19**. Washington, D.C., EUA: OPAS, 2020. Disponível em: <https://www.paho.org/pt/covid19/historico-da-pandemia-COVID-19>. Acesso em: 19 maio 2021.
- RAYMUNDO, C. E.; OLIVEIRA, M. C.; ELEUTÉRIO, T. de A.; ANDRÉ, S. R.; SILVA, M. G. da; QUEIROZ, E. R. da S.; MEDRONHO, R. de A. Spatial analysis of COVID-19 incidence and the sociodemographic context in Brazil. **PLoS ONE**, v. 16, n. 3, p. e0247794, 2021. <https://doi.org/10.1371/journal.pone.0247794>
- ROCHA, R.; RIFAT, A. F. R. C. P.; MASSUDA, A.; RACHE, B.; SPINOLA, P.; NUNES, L.; LAGO, M.; CASTRO, M. C. C. Effect of socioeconomic inequalities and vulnerabilities on health-system

preparedness and response to COVID-19 in Brazil: a comprehensive analysis. Open Access, v. 9, n. 6, p. E782-E792, 2021 [https://doi.org/10.1016/S2214-109X\(21\)00081-4](https://doi.org/10.1016/S2214-109X(21)00081-4)

SANTOS, A. A. L. da; SILVA, J. P.; SILVA, T. C. L. da; SOUZA, T. A.; MIRANDA, F. A. N de; TORRES, G. de V. Influência de indicadores sociais na incidência e mortalidade da COVID-19 no Brasil em junho de 2020. **Saúde e Pesquisa**, v. 15, n. 1, p. 1-10, 2022. <https://doi.org/10.17765/2176-9206.2022v15n1.e9559>

SILVA, W. M. da.; BRITO, P. dos S.; SOUSA, G. da S. de S.; SANTOS, L. F. S.; SILVA, J. C. Da; COSTA, A. C. P. de J.; PASCOAL, L. M.; SANTOS, F. S.; FONTOURA, I. G.; LOBATO, J. S. M.; FONTOURA, V. M.; PEREIRA, A. L. F.; SANTOS, L. H. dos; SANTOS NETO, M. Deaths due to COVID-19 in a state of northeastern Brazil: spatiotemporal distribution, sociodemographic and clinical and operational characteristics. **Transactions of The Royal Society of Tropical Medicine and Hygiene**, v. 116, n. 2, p. 163-172, 2022. <https://doi.org/10.1093/trstmh/trab098>

SILVA, Y.S.; RODRIGUES, Z. M. R. **Uso do geoprocessamento nas análises da Geografia da Saúde** v.1, Edição Especial, p. 189-199, 2022 (Dossiê Perspectivas Caleidoscópicas da Geografia da Saúde). <https://doi.org/10.53528/geoconexes.v1i1.69>

SILVA, A. F. da; BEZERRA, B. M. D.; DA SILVA, V. S.; ROMERO, J. A. R. A pandemia de Covid-19 em municípios do Ceará: correlação entre o índice de desenvolvimento humano municipal, taxa de incidência acumulada e taxa de letalidade. **Brazilian Journal of Development**, v. 9, n. 1, p. 4238–4251, 2023. <https://doi.org/10.34117/bjdv9n1-292>

SILVA, G. D. M. da; SOUZA, A. A. de; CASTRO, M. S. M. de; MIRANDA, W. D. de; JARDIM, L. L.; SOUSA, R. P. de. Influência da desigualdade socioeconômica na distribuição das internações e dos óbitos por COVID-19 em municípios brasileiros, 2020: um estudo ecológico. **Epidemiologia e Serviços de Saúde**, v. 32, n. 1, p. e2022303, 2023b. <https://doi.org/10.1590/s2237-96222023000100021>

SOUZA, S. da S. de; CUNHA, A. C. da; SUPPLICI, S. E. R.; ZAMPROGNA, K. M.; LAURINDO, D. L. Influência da cobertura da atenção básica no enfrentamento da COVID-19/ Influence of basic care coverage on coping with COVID-19/ Influência del cuidado básico de salud en el afrontamiento del COVID-19. **Journal Health NPEPS**, v. 6, n. 1, 2021. <https://doi.org/10.30681/252610104994>

SOUZA, C. D. F.; MACHADO, M. F.; CARMO, R. F. Human development, social vulnerability and COVID-19 in Brazil: a study of the social determinants of health. **Infect Dis Poverty**, v. 31, n. 9, p. 124, 2020. <https://doi.org/10.1186/s40249-020-00743-x>

TEIXEIRA, K. K. dos S.; CARVALHO, K. M. G.; ALMEIDA, M. de; BARBOSA, I. R. Indicadores de casos e óbitos por COVID-19 e sua relação com fatores contextuais: um estudo ecológico na cidade de Natal-RN / Indicators of cases and deaths by COVID-19 and its relationship with contextual factors: an ecological study in the city of Natal-RN. **Brazilian Journal of Development**, v. 6, n. 6, p. 40689–40703, 2020. <https://doi.org/10.34117/bjdv6n6-562>

VILLELA, D. A. M. Household crowding hampers mitigating the transmission of SARS-CoV-2. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 54, p. e08212020, 2021. <https://doi.org/10.1590/0037-8682-0821-2020>

WHO. 2020. **COVID 19 Public Health Emergency of International Concern**: (PHEIC) Global research and innovation forum: towards a research roadmap. Disponível em: [https://www.who.int/publications/m/item/COVID-19-public-health-emergency-of-international-concern-\(pheic\)-global-research-and-innovation-forum](https://www.who.int/publications/m/item/COVID-19-public-health-emergency-of-international-concern-(pheic)-global-research-and-innovation-forum). Acesso em: 18 set. 2021.

WHO. 2022. **COVID-19 Weekly Epidemiological Update** Edition 120 published 30 November 2022.

WOLLENSTEIN-BETECHS, S.; SILVA, A. A. B.; FLECK, J. L. CASSANDRAS, C. G.; PASCHALID, I. C. 2020. Physiological and socioeconomic characteristics predict COVID-19 mortality and resource utilization in Brazil. **PLOS ONE**, v. 15, n. 10, p. e0240346. <https://doi.org/10.1371/journal.pone.0240346>