

## Fatores múltiplos da Covid-19: Uma análise aplicada para municípios brasileiros

Juliana Gonçalves Taveira<sup>1</sup>  | Hilton Manoel Dias Ribeiro<sup>2</sup>  | Vinícius de Azevedo Couto Firme<sup>3</sup> 

<sup>1</sup> Universidade Federal de Juiz de Fora - Campus GV. E-mail: juliana.goncalves@ufjf.br

<sup>2</sup> Universidade Federal de Juiz de Fora - Campus GV. E-mail: hilton.manoel@ufjf.br

<sup>3</sup> Universidade Federal de Juiz de Fora - Campus GV. E-mail: vinicius.firme@ufjf.br

### RESUMO

Casos, óbitos, incidência, mortalidade e letalidade, associados à Covid-19, sugerem que esta pandemia gerou transtornos regionalmente distintos no Brasil. Logo, considerando dados de 2020 e valendo-se de regressões via *Mínimos Quadrados Ordinários* (MQO) e *Binomiais Negativas* (BN), este estudo avaliou se certas características dos municípios brasileiros poderiam afetar a intensidade local da pandemia. Os resultados sugerem que municípios de menor porte, com clima ameno e seco, gastos adequados em saúde e bom nível educacional, população majoritariamente idosa e composta por homens, menor atividade econômica, baixa desigualdade e poluição e um bom sistema de transporte público teriam menos casos/óbitos. Além de revelar associações relativas à incidência e à mortalidade, verificou-se que a letalidade da doença seria menor em cidades mais ricas, com população entre 20-39 anos, melhor transporte público, bom nível educacional, baixos níveis de densidade populacional e de poluição, maiores gastos em saúde e mais hospitais.

### PALAVRAS-CHAVE

Covid-19, Análise regional, Métodos quantitativos

### Multiple factors of Covid-19: An applied analysis for Brazilian municipalities

### ABSTRACT

The cases, deaths, incidence, mortality and lethality from Covid-19 suggest that this pandemic generated regionally distinct disorders in Brazil. Therefore, considering data from 2020 and using regressions via Ordinary Least Squares (OLS) and Negative Binomials (BN), this study assessed whether certain characteristics of Brazilian municipalities could affect the local intensity of this pandemic. The results suggest that smaller municipalities, with a mild and dry climate, adequate spending on health, good educational level, population that is mostly elderly and made up of men, less economic activity, low inequality and pollution and a good public transport system would have fewer cases/deaths. In addition to revealing associations regarding incidence and mortality, it was found that the lethality would be lower in richer cities, with a population between 20-39 years old, better public transport, a good educational level, low levels of population density and pollution, higher health spending and more hospitals.

### KEYWORDS

Covid-19, Regional analysis, Quantitative methods

### CLASSIFICAÇÃO JEL

I10, R58, C2

## 1. Introdução

A pandemia de Covid-19, desencadeada pelo coronavírus (SARS-CoV-2), apresentou um desafio sem precedentes para a saúde pública global. Desde o surgimento dos primeiros casos, na cidade de Wuhan, China, no final de 2019 (Khatib, 2020), o vírus se espalhou rapidamente pelo mundo, afetando milhões de pessoas, sobrecarregando os sistemas de saúde de diversos países (Arbix, 2020; Pedersen e Favero, 2020) e revelando desigualdades socioeconômicas e sanitárias significativas, no nível local (Firme et al., 2022). Segundo dados do Ministério da Saúde (MS, 2024), o Brasil já registrava mais de 37,7 milhões de casos de Covid-19 e 704.488 óbitos, até julho/2023, o que representa uma mortalidade de 335,2 (a cada 100 mil habitantes) e uma letalidade de 1,9%.

Na realidade, o Brasil, com suas dimensões continentais e desigualdades internas, foi um dos países mais afetados pela pandemia (Neiva et al., 2020), tornando-se um local propício ao estudo dos fatores locais que, em tese, poderiam afetar os indicadores associados à Covid-19 (*i.e.*: total de casos e óbitos e taxas de incidência, mortalidade e letalidade). Para Firme, Ribeiro e Taveira (2022), alguns fatores socioeconômicos municipais desempenhariam um papel crucial na propagação e/ou na severidade local da doença. Neste contexto, entender quais características municipais poderiam influenciar as estatísticas associadas à Covid-19 torna-se relevante, pois permite propor políticas públicas, regionalizadas, a fim de mitigar futuras pandemias no país.

Para tanto, esta pesquisa contabilizou o total de casos e óbitos por Covid-19, em cada município brasileiro, no ano de 2020, e valeu-se de regressões via *Mínimos Quadrados Ordinários*, *Poisson* e *Binominal Negativo*. Os resultados sugerem que municípios de menor porte, com clima ameno e seco, gastos adequados em saúde e bom nível educacional, população majoritariamente idosa e composta por homens, menor atividade econômica, pouca desigualdade interna, baixa poluição veicular e um bom sistema de transporte público teriam menos casos e óbitos por Covid-19. Além de revelar certas associações relativas à incidência e à mortalidade, as estimativas também indicaram que a letalidade da doença seria menor entre as cidades mais ricas, com população tipicamente adulta (entre 20-39 anos), melhor transporte público, bom nível educacional, baixos níveis de densidade populacional e de poluição veicular, maiores gastos em saúde e com mais hospitais. Acredita-se que tais resultados possam auxiliar a formulação de políticas públicas mais efetivas, que levem em consideração as peculiaridades municipais e permitam minimizar futuros surtos da doença.

O restante do trabalho está organizado da seguinte forma: a próxima seção revela os possíveis determinantes dos casos e óbitos de Covid-19. Logo após, tem-se a descrição da metodologia e da base de dados. Resultados, considerações finais e referências são apresentados em sequência.

## 2. Fatores Locais Associados à Covid-19

Após a pandemia de Covid-19, houve um considerável esforço de pesquisa, no sentido de compreender os fatores que poderiam favorecer/dificultar o controle local desta doença e, assim, evitar que episódios extremos se repitam. Logo, buscou-se destacar algumas dessas contribuições, que abordaram a relação de indicadores socioeconômicos, demográficos, climáticos e de saúde com as principais estatísticas associadas à Covid-19.

No que tange aos fatores socioeconômicos, Mollalo *et al.* (2020) encontraram uma relação positiva entre a desigualdade de renda e o aumento dos casos de Covid-19, em certos condados dos Estados Unidos. Essa associação pode estar relacionada à concentração populacional, típica de grandes centros urbanos, onde a desigualdade tende a ser mais acentuada. Assim, essa variável pode refletir a influência da aglomeração populacional na propagação do vírus. O mesmo parece ocorrer com a renda *per capita* local, que seria positivamente associada ao número de casos e/ou óbitos por Covid-19 (Williams e Cooper, 2020; Wadhwa *et al.*, 2020; Cole *et al.*, 2020; Credit, 2020; Rafael *et al.*, 2020; Jinjarak *et al.*, 2020; Firme *et al.*, 2022), pois locais com maior atividade econômica teriam mais interação social, oriunda da movimentação de trabalhadores (Ehlert, 2021; Stojkoski *et al.*, 2020).

Analisando os bairros de Nova York, Wadhwa *et al.* (2020) descobriram que os locais com menor nível educacional apresentaram maiores taxas de hospitalização e mortalidade por Covid-19. Resultado semelhante foi obtido por Firme, Ribeiro e Taveira (2022), para os municípios de Minas Gerais. Segundo Ehlert (2021), indivíduos mais educados teriam melhores condições financeiras e, portanto, maior acesso a serviços de saúde, tratamentos médicos diferenciados e informações privilegiadas sobre a doença. Apesar disso, conforme descrito anteriormente, as regiões mais ricas, possivelmente pela concentração de pessoas, apresentariam mais casos e óbitos por Covid-19.

Sobre os fatores demográficos, estudos indicam que a densidade e o porte populacional poderiam impulsionar os casos, óbitos (Stojkoski *et al.*, 2020; Ehlert, 2021; Cole *et al.*, 2020; Jinjarak *et al.*, 2020; Firme *et al.*, 2022) e a mortalidade associada à Covid-19 (Jinjarak *et al.*, 2020). Devido à necessidade de cuidados especializados e procedimentos complexos (em casos mais graves da doença) é compreensível que haja concentração dos registros em grandes centros urbanos, cuja infraestrutura médico-hospitalar é mais avançada. Ademais, o risco de morte revela-se maior entre os homens (Lippi *et al.*, 2020). Acredita-se que a maior predisposição masculina a hipertensão, doenças cardiovasculares e respiratórias (potencialmente associadas a um maior consumo de álcool e tabaco) possa explicar esse resultado (Gebhard *et al.*, 2020).

Quanto à poluição e ao clima, Wu *et al.* (2020) e Cole *et al.* (2020), após avaliarem certos municípios dos EUA e da Holanda, respectivamente, notaram que regiões

com atmosfera mais poluída apresentariam mais casos e óbitos por Covid-19. Ambos sugerem que a inalação prolongada de poluentes poderia comprometer a capacidade cardíaca e respiratória, agravando os sintomas do coronavírus e, desse modo, contribuindo para uma maior notificação de casos, internações e óbitos. No que tange ao clima, Ma *et al.* (2020) e Auler *et al.* (2020) afirmam que altas temperaturas e maior umidade do ar aumentariam os casos e óbitos de Covid-19. Além desses, Pirouz *et al.* (2020) sugerem que uma maior umidade relativa aumentaria os casos, enquanto a temperatura elevada os reduziria. No Brasil, cujo clima é predominantemente tropical, os locais mais quentes e úmidos poderiam dificultar o distanciamento social (Firme *et al.*, 2022). Alternativamente, Teixeira e Carvalho (2020) argumentam que baixas temperaturas e reduzida umidade do ar poderiam aumentar a sobrevivência do SARS-CoV-2 fora do corpo humano. Portanto, a questão sobre o clima envolve descobrir qual desses argumentos seria mais relevante no local analisado.

Por fim, a condição médico-hospitalar local revela sua capacidade de realizar diagnósticos em massa e lidar com epidemias mais severas. Embora uma estrutura médico-hospitalar adequada possa reduzir os óbitos associados ao corona-vírus (Firme *et al.*, 2022), é possível que aumente os casos, visto que haveria mais testagem nesses locais (Stojkoski *et al.*, 2020). Como um número maior de casos pode gerar mais óbitos, o efeito da infraestrutura de saúde pode divergir em estudos agregados (ecológicos) e individuais (Ehlert, 2021). As variáveis usualmente usadas para medir a infraestrutura de saúde incluem os gastos nessa área, o número de hospitais, de médicos e enfermeiros e a cobertura de serviços essenciais à saúde (Ehlert, 2021; Mollalo *et al.*, 2020; Stojkoski *et al.*, 2020). Outro fator relevante refere-se às comorbidades pré-existentes na população local (*i.e.*: doenças crônicas e etiologicamente correlatas à Covid-19). Para Gebhard *et al.* (2020), estas doenças (*e.g.*: câncer, diabetes, hipertensão, problemas cardíacos e respiratórios) agravariam os sintomas do coronavírus, aumentando as estatísticas associadas à doença (Gebhard *et al.*, 2020; Lippi *et al.*, 2020; Firme *et al.*, 2022).

Em conjunto, esses fatores socioeconômicos, demográficos, climáticos e de saúde poderiam influenciar o controle de surtos locais de doenças do tipo SARS, facilitando-o ou dificultando-o.

### 3. Metodologia

Considerando dados de corte transversal (*cross-section*), referentes aos municípios brasileiros no ano de 2020, buscou-se avaliar a relação entre as características locais (descritas na seção anterior) e os principais indicadores da Covid-19. Logo, usando os casos, os óbitos, a incidência, a mortalidade e a letalidade dessa doença como variáveis dependentes ( $Covid_i$ ), estimou-se (Equação 1):

$$Covid_i = \alpha + \beta_1 Socio_i + \beta_2 Demo_i + \beta_3 Clima_i + \beta_4 Saude_i + \gamma_1 Reg_i + \varepsilon_i \quad (1)$$

Na Equação 1, representa a constante do modelo e são os coeficientes associados às variáveis testadas. Os termos  $Socio_i$ ,  $Demo_i$ ,  $Clima_i$  e  $Saude_i$  englobam as múltiplas variáveis utilizadas para captar as condições socioeconômicas, demográficas, climáticas (inclusive poluição) e de saúde inerentes aos  $i$  municípios brasileiros, respectivamente. Por fim,  $Reg_i$  são *dummies* de controle regional (para cada unidade da federação) e  $\varepsilon_i$  é um termo de erro.

A Equação 1 permite verificar se as estatísticas associadas ao primeiro ano de pandemia (*i.e.*: 2020) poderiam ser explicadas por características municipais específicas. Inicialmente, usou-se o teste F, apenas com *dummies* regionais ( $Reg_i$ ), a fim de verificar se a variação intra-regional (*within*) é importante para explicar as estatísticas de Covid-19 ( $Covid_i$ ). Assim, rejeitando-se a hipótese nula, o modelo com controles regionais seria o mais adequado.

Como os casos e óbitos municipais de Covid-19 são discretos e não negativos (*i.e.*: dados de contagem), a regressão via *Mínimos Quadrados Ordinários* (MQO) seria inadequada, devido à heterocedasticidade e à não normalidade inerentes aos dados de contagem. Nesta situação, o método de *Poisson* é recomendado. Contudo, a consistência/eficiência desse estimador requer que a variância condicional seja igual à média condicional. Quando há *super-dispersão* (*i.e.*: variância condicional superior à média condicional), a estimação *Binomial Negativa* (que é uma generalização do *Poisson*, para casos com *super-dispersão*) é preferível (Greene, 2002).

Nesta pesquisa, utilizaram-se o teste de qualidade de ajustamento *qui-quadrado* (que verifica se o modelo se ajusta aos dados) e a razão de verossimilhança (que avalia a *super-dispersão*), para definir entre o *Poisson* e o *Binomial Negativo*. Como ambos os testes indicaram o uso do *Binomial Negativo*, apenas os seus resultados foram reportados. Nos demais casos (*i.e.*: incidência, mortalidade e letalidade), usou-se o MQO, com os erros-padrões robustos sugeridos por Cameron e Trivedi (2010).

### 3.1 Base de dados

Visando avaliar quais características municipais afetariam as principais estatísticas associadas à Covid-19, no Brasil, os seguintes dados foram considerados:

- Variáveis dependentes ( $Covid_i$ ): trata-se do total de casos e de óbitos por Covid-19, de cada município brasileiro, no ano de 2020 (disponibilizados pelas Secretarias Estaduais de Saúde, das 27 unidades federativas do Brasil). A partir disso, calcularam-se as taxas de incidência e mortalidade (*i.e.*: número de casos ou óbitos dividido pela população local vezes 100 mil), bem como a letalidade associada à doença (*i.e.*: óbitos divididos pelos casos vezes 100).

Como as variáveis explicativas podem apresentar uma relação multidirecional em relação à  $Covid_i$ , todas foram consideradas em períodos anteriores à pandemia (*i.e.*: 2020). Conforme descrito na Equação 1, essas variáveis podem ser divididas em:

1. Fatores socioeconômicos (*Socio<sub>i</sub>*): para o nível de atividade econômica, utilizou-se o PIB per capita corrente de 2019, calculado pelo *Instituto Brasileiro de Geografia e Estatística* - IBGE; descrito na Equação 1, estas variáveis podem ser divididas em: quanto ao mercado de trabalho, usou-se o percentual de trabalhadores (formais) empregados na indústria, no comércio, na agricultura e nos serviços, conforme indicado na *Relação Anual de Informações Sociais* - RAIS; com base na renda média desses trabalhadores (RAIS), calculou-se um índice de GINI<sup>1</sup> municipal, para o ano de 2019, para aferir a desigualdade; como *proxy* de educação, usou-se o percentual de trabalhadores com ensino superior completo (RAIS);<sup>2</sup> a relação de ônibus e micro-ônibus *per capita* foi usada para medir potenciais aglomerações oriundas do transporte público.
2. Fatores demográficos (*Demo<sub>i</sub>*): visando controlar questões de gênero e aspectos etários, utilizaram-se dados de 2019, referentes à parcela de homens, na população total, estimada pelo *Tribunal de Contas da União* - TCU, e o percentual de indivíduos com até 19 anos, entre 20-39 anos, 40-59 anos e 60 anos ou mais; para a aglomeração local, usou-se a densidade populacional (*i.e.*: população dividida pela área geográfica municipal); ademais, incluíram-se *dummies* para os municípios *pequenos* (*i.e.*: com população inferior a 10 mil habitantes), *médios* (entre 10 e 50 mil habitantes), *grandes* (50 a 150 mil habitantes) e *muito grandes* (com população superior a 150 mil habitantes).
3. Poluição e fatores climáticos (*Clima<sub>i</sub>*): visando mensurar a poluição, usou-se a densidade veicular (*i.e.*: número de veículos, cadastrados na *Secretaria Nacional de Trânsito* - STN, dividido pela área municipal). Ademais, usaram-se as médias de precipitação pluviométrica (em milímetros/mês) e de temperatura (em graus centígrados), calculados pelo *Climate Research Unit* da *University of East Anglia*, referentes ao mês de dezembro de 2011 (IPEADATA, 2020).<sup>3</sup>
4. Indicadores de Saúde (*Saude<sub>i</sub>*): consideraram-se os gastos correntes *per capita*, alocados em saúde e saneamento, obtidos junto à *Secretaria do Tesouro Nacional*; para medir a estrutura de saúde, utilizou-se o total de hospitais e de leitos (a cada 100 mil habitantes) e o percentual da população coberta por *Equipes de Saúde da Família e de Atenção Básica*, retirados do DATASUS.<sup>4</sup>

<sup>1</sup>O índice de GINI é, geralmente, calculado com base na renda domiciliar *per capita*. Contudo, dada a indisponibilidade de dados recentes por município, usou-se a renda média dos trabalhadores formais, disponível na RAIS.

<sup>2</sup>Como esta *proxy* inclui apenas trabalhadores formais, é possível que os resultados associados à educação possuam algum tipo de *viés de seleção*, visto que os empregos formais são, em geral, ocupados por indivíduos com melhor nível educacional (quando comparados ao mercado informal). Esse problema tende a ser mais grave em cidades pequenas.

<sup>3</sup>Embora o *Instituto Nacional de Meteorologia* - INMET (<https://portal.inmet.gov.br/dadoshistoricos>) possua dados mais atuais sobre temperatura e precipitação, eles estão disponíveis apenas para uma pequena parcela dos municípios brasileiros (no ano de 2020, havia informações somente para 589 dos 5570 municípios).

<sup>4</sup>O percentual de indivíduos com plano de saúde privado também foi testado. Contudo, dado o elevado número de *missings* e a ausência de significância nas estimações, optou-se por sua exclusão.

5. *Dummies Regionais* ( $Reg_i$ ): a fim de garantir que as diferenças nas estatísticas municipais de Covid-19 não seriam apenas um reflexo da heterogeneidade oriunda das regiões brasileiras, todos os modelos contaram com variáveis binárias (*dummies*), que assumem um valor unitário, quando o município pertence a uma determinada Unidade da Federação – UF, e zero, quando contrário.

A Tabela 1 apresenta as principais estatísticas descritivas dos dados utilizados na pesquisa.

**Tabela 1.** Estatísticas descritivas da base de dados

Observações: 5570	Variáveis	Média	Desvio-padrão	Min.	Max.
COVID-19	Nº de Casos (acumulados em 2020)	1.372,13	8.078,98	2,00	401.718,00
	Nº de Óbitos (acumulados em 2020)	34,95	325,70	0,00	15.679,00
	Incidência (p/100 mil habitantes)	3.128,33	2.196,32	28,21	23.421,80
	Mortalidade (p/100 mil habitantes)	57,06	43,23	0,00	350,70
	Letalidade (óbitos/casos*100)	2,23	2,13	0,00	33,33
Socioeconômicos	PIB per capita (R\$ milhar)	24,55	25,55	4,48	464,88
	Trabalhadores na indústria (%)	14,54	16,45	0,00	86,70
	Trabalhadores na agricultura (%)	11,42	14,24	0,00	92,89
	Trabalhadores no comércio (%)	15,95	9,47	0,00	80,72
	Trabalhadores em serviços (%)	58,08	21,35	2,37	100,00
	Índice de Gini (Índice: 0 a 1)	0,29	0,05	0,04	0,66
	Trabalhadores c/ superior completo (%)	18,81	9,73	0,00	90,97
Demográficos	Nº de ônibus (p/100 mil habitantes)	543,08	743,39	0,00	49.734,04
	Homens (% na população total)	50,36	1,92	43,14	93,65
	Pessoas com até 19 anos (%)	28,81	5,58	4,97	57,22
	Pessoa com 20 a 39 anos (%)	31,31	2,75	18,68	71,84
	Pessoa com 40 a 59 anos (%)	24,78	3,34	10,34	36,22
	Pessoa com 60 ou mais (%)	15,10	4,49	2,46	36,31
Clima	Densidade populacional (Pop./Km2)	119,92	627,85	0,05	14.207,57
	População (total municipal)	37.728	221.458	781	12.300.000
	Densidade veicular (veículos/Km2)	58,68	331,91	0,00	9.674,26
Saúde	Temperatura (graus centígrados)	22,83	3,02	14,00	28,04
	Precipitação (milímetros/mês)	115,88	36,91	28,87	282,43
	Gasto em saúde (R\$ per capita)	921,58	429,20	0,00	5.056,51
	Leitos (p/100 mil habitantes)	150,71	190,34	0,00	3056,46
	Hospitais (p/100 mil habitantes)	126,36	179,49	0,00	3056,46
	Cobertura Atenção Básica (%)	92,74	16,38	0,00	100,00

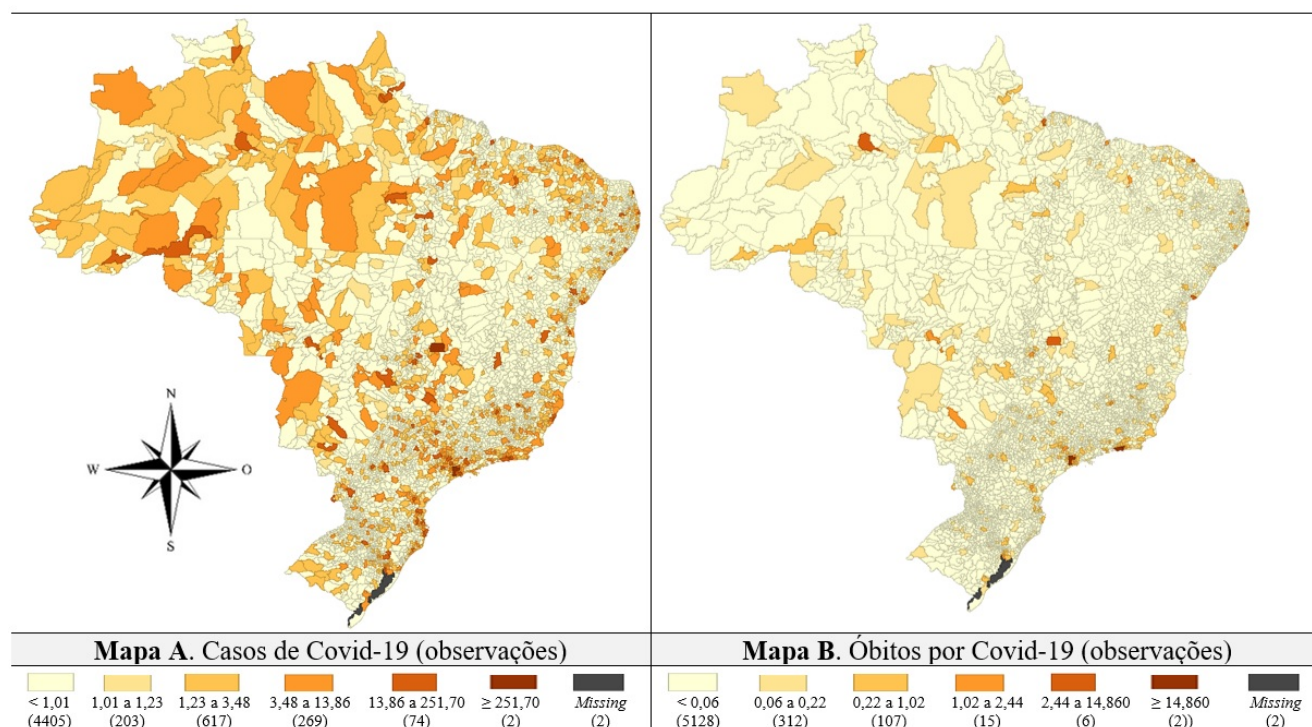
Fonte: Elaboração própria. Nota: Variáveis com *missings*: densidade veicular (5562), temperatura e precipitação (5506) e gastos em saúde (5553).

No ano de 2020, os municípios brasileiros apresentaram, em média, 1.372 casos e 34,9 óbitos associados à Covid-19, o que representa uma letalidade de, aproximadamente, 2,2%. A incidência e a mortalidade ficaram em torno de 3.128 casos e 57 óbitos, a cada 100 mil habitantes, respectivamente. O PIB *per capita* variou de R\$ 4.482 a R\$ 464.883 entre os municípios, mantendo uma média de R\$ 24,5 mil. Em média, a população municipal foi de 37.728 habitantes, com mínimo de 781 e máximo superando os 12 milhões. Boa parte da população está na faixa dos 20-39 anos (31,3%) e os homens representam pouco mais de 50% da população total. Ademais, quase 60% dos trabalhadores estavam empregados no setor de serviços neste ano, um dos mais afetados pelas medidas restritivas impostas para controle da doença. O gasto *per capita* municipal, na área da saúde, ficou em torno de R\$ 921,58 e o número de leitos e de hospitais (a cada 100 mil habitantes) foi de, aproximadamente, 151 e

126, respectivamente (Tabela 1).

Na Figura 1, pode-se observar a distribuição dos casos e óbitos, associados à Covid-19, entre os municípios brasileiros.

**Figura 1.** Casos e Óbitos de Covid-19 no ano de 2020



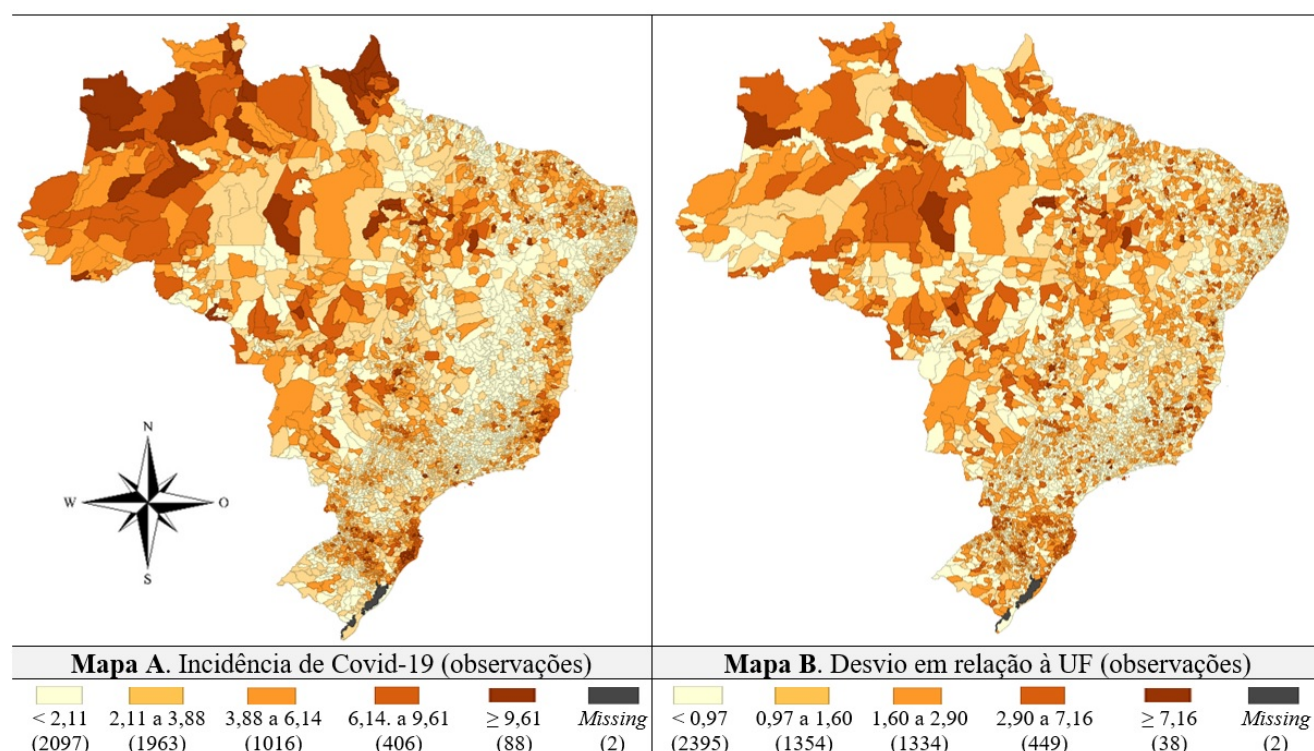
Fonte: Elaboração própria.

Nota: 1) para melhor visualização, os valores da legenda foram divididos por mil (e.g.: as primeiras faixas dos Mapas A e B, 0.52 e 0.08 revelam um total de 516 casos e 76 óbitos, respectivamente). 2) Escala: 1:250.000.

Embora a maioria dos casos se concentre na cidade de São Paulo (Figura 1), a Figura 2 revela que a incidência foi maior no município de Porteirão (Goiás). Ademais, os desvios da incidência de cada município, em relação às médias de suas respectivas *Unidades da Federação* UF, sugerem que existem outros fatores locais (além daqueles inerentes a cada UF) influenciando a severidade da doença.

A distribuição espacial da Covid-19, no Brasil, tem sido complexa e parece ser influenciada por uma série de fatores (alguns deles descritos na seção 2) que acabam gerando uma significativa heterogeneidade espacial nos indicadores da doença, com alguns estados enfrentando surtos graves e outros com níveis brandos de transmissão. De modo geral, estados com grandes centros urbanos, como São Paulo e Rio de Janeiro, vivenciaram maiores desafios na contenção do vírus, enquanto aqueles com menor densidade populacional, como os da região Norte, tiveram problemas relacionados à infraestrutura e ao acesso a serviços médicos. Deste modo, a análise dos fatores que, em tese, explicariam a distribuição espacial da Covid-19, no Brasil, é potencialmente promissora, pois permitiria formular estratégias locais de combate à pandemia.



**Figura 2.** Incidência da Covid-19 e seu desvio em relação à média da UF

Fonte: Elaboração própria.

Nota: 1) para melhor visualização, os valores da legenda foram divididos por mil (e.g.: 9.61 representa uma incidência de 9614.2 casos, para cada 100 mil habitantes). 2) Escala: 1:250.000.

#### 4. Resultados e Discussão

Com o objetivo de verificar quais características municipais poderiam afetar os indicadores da Covid-19, utilizaram-se o estimador *binomial negativo*, para o total de casos e de óbitos da doença (Tabela 2), e o método de *mínimo quadrados ordinários*, para as taxas de incidência, mortalidade e letalidade (Tabela 3). Em todas as estimações, incluiu-se o controle de efeitos fixos de região (*i.e.*: *dummies* estaduais), para garantir que os parâmetros estimados indiquem a contribuição das variáveis em relação às médias estaduais.

Como boa parte das *dummies* estaduais revelaram-se significativas, nas estimativas da Tabela 2, pode-se inferir que parte da variância municipal dos casos/óbitos de Covid-19 se deve às diferenças inerentes às UFs (efeito *between*). Ademais, ao incluir as variáveis explicativas em bloco (*i.e.*: socioeconômicas, demográficas, climáticas e de saúde, respectivamente), notou-se uma melhora nos testes F e de Wald, bem como nos critérios AIC, BIC,  $R^2$  e Pseudo  $R^2$ , sugerindo que o conjunto de variáveis é relevante e ajudaria a explicar parte da variância nos casos e óbitos de Covid-19.

Embora os modelos estimados não assegurem relações causais, entre as variáveis explicativas e a dependente, seus coeficientes são relevantes, pois permitem verificar quais características municipais devem ser observadas, pelos formuladores de po-

líticas públicas, no enfrentamento de outras pandemias como a da Covid-19. Dito isto, notou-se que todas as variáveis socioeconômicas apresentaram parâmetros significativos sobre os casos e óbitos (Tabela 2). Conforme esperado, o PIB *per capita* apresentou um sinal positivo/significativo associado aos casos (em todos os modelos) e aos óbitos (significativo no modelo completo, com todas as variáveis da Equação 1). É possível que as aglomerações, típicas de locais com maiores níveis de atividade econômica, expliquem parte desse resultado. Além disso, verificou-se que possuir uma elevada concentração de trabalhadores na indústria e no comércio (em relação ao setor de serviços, excluído), bem como um maior nível de desigualdade local (medida via índice de *Gini*), poderia aumentar a vulnerabilidade dos municípios diante da pandemia (*i.e.*: efeito positivo sobre os casos e óbitos), conforme previamente indicado por Stojkoski *et al.* (2020) e Ehlert *et al.* (2021).

Os resultados ainda indicam que possuir mais ônibus por habitante, possivelmente por reduzir as aglomerações provenientes do transporte público, poderia minimizar os casos e óbitos. O mesmo ocorre em locais com maior percentual de trabalhadores com ensino superior, que (em tese) teriam maior possibilidade de aderir ao trabalho remoto e maior capacidade de compreensão sobre as informações relacionadas à Covid-19 (Tabela 2).

Contrariando Lippi *et al.* (2020), mas convergindo com os resultados de Firme, Ribeiro e Taveira (2022), observou-se que locais com um maior percentual de homens enfrentariam menos casos e óbitos associados à Covid-19. Alternativamente, populações mais jovens, talvez por serem mais avessas às medidas de restrição social, impulsionariam ambas as estatísticas. O total de casos e de óbitos revelaram-se inferiores nos municípios pequenos (referência) e aumentaram entre os de porte médio, grande e muito grande, respectivamente. Os efeitos atribuídos à densidade populacional mostraram-se ambíguos e merecem cautela, com modelos restritos (*i.e.*: sem todas as variáveis de controle) sugerindo que locais mais densos teriam mais casos e óbitos e modelos irrestritos sugerindo o oposto.

Notou-se que locais com maior densidade veicular e clima, predominantemente, quente e chuvoso enfrentariam mais casos e óbitos. Segundo Firme, Ribeiro e Taveira (2022), é possível que o isolamento social seja mais oneroso para os habitantes de locais quentes e úmidos, o que poderia impulsionar tanto os casos quanto os óbitos. Já a poluição veicular poderia agravar os sintomas do coronavírus, aumentando a notificação de casos e os óbitos (Wu *et al.*, 2020; Cole *et al.*, 2020). Ademais, verificou-se que maiores gastos (*per capita*) com saúde e saneamento e uma boa cobertura à atenção básica poderiam minimizar os indicadores associados à pandemia. Já municípios com mais hospitais (por habitante) teriam menos óbitos. Todavia, a oferta de leitos hospitalares apresentou uma relação positiva com ambas as estatísticas de Covid-19. Como boa parte dos municípios brasileiros não possuem leitos, é possível que as cidades que os ofereçam acabem atraindo pessoas em estágios mais graves da doença.

Visando facilitar a visualização das associações entre as características municipais

(testadas nesta pesquisa) e as taxas de incidência, mortalidade e letalidade de Covid-19, optou-se por reportar apenas os sinais estimados e suas respectivas significâncias (Tabela 3).

**Tabela 2.** Fatores municipais associados ao número de casos e óbitos de Covid-19 em 2020

Variáveis	Número de casos				Número de óbitos			
PIB <i>per capita</i>	0,007*** (0,002)	0,004*** (0,001)	0,003*** (0,001)	0,006*** (0,001)	0,002 (0,001)	0,001 (0,000)	0,001 (0,000)	0,003*** (0,001)
Trabalhadores na indústria (%)	0,013*** (0,002)	0,009*** (0,001)	0,009*** (0,001)	0,008*** (0,001)	0,012*** (0,002)	0,007*** (0,001)	0,007*** (0,001)	0,006*** (0,001)
Trabalhadores na agricultura (%)	-0,009*** (0,002)	-0,001 (0,001)	-0,000 (0,001)	-0,001 (0,001)	-0,006*** (0,002)	0,002** (0,001)	0,002** (0,001)	0,002** (0,001)
Trabalhadores no comércio (%)	0,063*** (0,003)	0,021*** (0,002)	0,023*** (0,002)	0,019*** (0,002)	0,065*** (0,003)	0,019*** (0,002)	0,020*** (0,002)	0,018*** (0,002)
Índice de Gini	0,128*** (0,006)	0,019*** (0,003)	0,018*** (0,002)	0,020*** (0,002)	0,153*** (0,007)	0,026*** (0,003)	0,024*** (0,003)	0,025*** (0,003)
Trabalhadores com superior completo	-0,017*** (0,002)	-0,002 (0,002)	-0,002* (0,001)	-0,002* (0,001)	-0,023*** (0,003)	-0,004** (0,002)	-0,004** (0,002)	-0,004** (0,002)
Nº de ônibus <i>per capita</i>	-0,000*** (0,000)	-0,000*** (0,000)	-0,000*** (0,000)	-0,000*** (0,000)	-0,001*** (0,000)	-0,000*** (0,000)	-0,000*** (0,000)	-0,000*** (0,000)
Homens (%)		-0,062*** (0,008)	-0,057*** (0,008)	-0,055*** (0,008)		-0,087*** (0,010)	-0,079*** (0,010)	-0,079*** (0,010)
Pessoa com até 19 anos (%)		0,010* (0,006)	0,018*** (0,006)	0,020*** (0,006)		0,020*** (0,007)	0,026*** (0,008)	0,024*** (0,008)
Pessoa com 20 a 39 anos (%)		0,074*** (0,006)	0,074*** (0,006)	0,073*** (0,006)		0,045*** (0,007)	0,042*** (0,008)	0,039*** (0,008)
Pessoa com 40 a 59 anos (%)		0,014 (0,010)	0,024** (0,010)	0,033*** (0,010)		0,035*** (0,013)	0,035*** (0,014)	0,041*** (0,013)
Densidade populacional		0,000*** (0,000)	-0,000*** (0,000)	-0,000*** (0,000)		0,000*** (0,000)	-0,000 (0,000)	-0,000* (0,000)
Cidade média		1,080*** (0,028)	1,060*** (0,028)	0,978*** (0,029)		1,175*** (0,032)	1,160*** (0,031)	1,075*** (0,032)
Cidade grande		2,182*** (0,043)	2,159*** (0,044)	2,063*** (0,045)		2,358*** (0,046)	2,347*** (0,046)	2,234*** (0,047)
Cidade muito grande		3,589*** (0,096)	3,516*** (0,082)	3,393*** (0,082)		3,817*** (0,087)	3,787*** (0,080)	3,651*** (0,079)
Densidade veicular			0,001*** (0,000)	0,001*** (0,000)			0,001*** (0,000)	0,001*** (0,000)
Temperatura			0,053*** (0,008)	0,059*** (0,008)			0,073*** (0,009)	0,082*** (0,008)
Precipitação			0,001 (0,000)	0,001** (0,000)			0,004*** (0,000)	0,004*** (0,000)
Gasto em saúde				-0,000*** (0,000)				-0,000*** (0,000)
Leitos				0,001*** (0,000)				0,000*** (0,000)
Hospitais				-0,000 (0,000)				-0,000** (0,000)
Cobertura Atenção Básica				-0,002** (0,001)				-0,003*** (0,001)
Efeito fixo regional	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Observations	5.568	5.562	5.504	5.488	5.568	5.562	5.504	5.488
Pseudo R2	0,070	0,127	0,128	0,130	0,137	0,240	0,242	0,245

Fonte: Elaboração própria. Notas: a) \*\*\*  $p < 0,01$ , \*\*  $p < 0,05$ , \*  $p < 0,1$ ; b) Estimacões binomiais negativas, com constante e erros-padrões robustos entre parênteses.

**Tabela 3.** Fatores municipais associados ao número de casos e óbitos de Covid-19 em 2020

Varáveis	Incidência			Mortalidade			Letalidade		
	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***
PIB per capita	+***	+***	+***	+***	+***	ns	-***	-***	ns
Trab. na indústria (%)	+***	+***	+***	+***	+***	+**	-***	-***	-***
Trab. na agricultura (%)	-**	-**	-*	ns	ns	ns	ns	ns	ns
Trab. no comércio (%)	+***	+***	+***	+***	+***	+***	ns	ns	ns
Índice de Gini	+***	ns	ns	+***	+***	ns	+**	ns	ns
Trab. com superior completo (%)	-**	-*	ns	-***	-**	-**	-**	-*	-**
Nº de ônibus	ns	ns	ns	-***	-***	-***	-***	-***	-***
Homens (%)	-***	-***	-***	-***	-***	-***	-***	-*	ns
Pessoa com até 19 anos (%)	-**	ns	ns	ns	ns	ns	ns	ns	ns
Pessoa com 20 a 39 anos (%)	+***	+***	+***	-*	-**	-**	-***	-***	-***
Pessoa com 40 a 59 anos (%)	ns	ns	ns	ns	ns	ns	ns	ns	ns
Densidade populacional	-***	-***	-***	+***	+***	+***	+***	+***	+***
Cidade Média	ns	ns	ns	+***	+***	+***	ns	ns	ns
Cidade Grande	ns	ns	ns	+***	+***	+***	+***	+***	+***
Cidade Muito Grande	+**	+**	+***	+***	+***	+***	+***	+***	+***
Densidade veicular	+***	+***	+**	+***	+***	+**	+***	+***	-**
Temperatura	+***	+***	+***	+***	+***	+***	ns	ns	ns
Precipitação	ns	ns	ns	+***	+***	+***	+***	+***	+***
Gasto em saúde per capita	+***	+***	+***	+***	+***	+*	-***	-***	-***
Leitos	+***	+***	ns	+***	+***	ns	+***	+***	ns
Hospitais	ns	ns	ns	ns	ns	-**	-*	-*	ns
Cobertura à Atenção Básica	+**	+**	ns	+**	ns	ns	ns	ns	ns
Efeito fixo regional	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***	Sim***
Observações	5.568	5.562	5.504	5.562	5.504	5.488	5.568	5.562	5.504
R2	0,282	0,291	0,302	0,190	0,210	0,213	0,074	0,089	0,102

Fonte: Elaboração própria. Notas: a) \*\*\* p<0,01, \*\* p<0,05, \* p<0,1; b) Estimções via *MGO*, com constante e erros-padrões robustos; c) ns = não significativo.

Os resultados indicam que municípios com maior PIB *per capita* e elevada concentração de trabalhadores na indústria e no comércio teriam maior incidência e mortalidade relacionada à Covid-19. Acredita-se que aglomeração urbana, típica desses locais, poderia explicar tais resultados (Ehlert, 2021). Todavia, as cidades mais ricas e voltadas ao setor industrial, possivelmente por possuírem mais recursos e infraestrutura, teriam menor letalidade. Alternativamente, possuir alta concentração de trabalhadores no setor agrícola (talvez por indicar locais menos povoados), poderia reduzir as taxas de incidência (Tabela 3).

Verificou-se que indivíduos com maiores níveis educacionais poderiam minimizar todas as taxas municipais associadas à pandemia. A desigualdade interna, embora pareça nociva a todas as estatísticas, não mostrou-se significativa nos modelos completos/irrestritos (neste caso, é possível que seu efeito já esteja sendo captado por outra variável). Ademais, notou-se que cidades com melhores serviços de transporte público teriam menores índices de mortalidade e letalidade.

Localidades com maior proporção de homens teriam taxas menores de incidência, mortalidade e, talvez, letalidade (este último não foi significativo no modelo completo). Embora precisem ser aprofundados, esses resultados convergem com os obtidos por Firme, Ribeiro e Taveira (2022), para os municípios de Minas Gerais. Quanto às faixas etárias, notou-se que locais com mais indivíduos entre 20 e 39 anos teriam maior incidência de Covid-19, porém menores taxas de mortalidade e letalidade. Acredita-se que, embora esse grupo não se encontre em uma faixa etária de risco (*i.e.*: crianças ou idosos), o que reduziria a mortalidade/letalidade, ele teria certa dificuldade em manter o distanciamento social, pois incluiria muitos jovens e trabalhadores (Tabela 3).

Curiosamente, locais com maior densidade populacional teriam menores taxas de incidência, porém maior letalidade. Neste caso, é possível que as *dummies* de porte populacional já captem o efeito da aglomeração, pois nota-se que as 3 taxas, associadas à Covid-19, seriam maiores em cidades grandes (entre 50 mil e 150 mil habitantes) e muito grandes (mais de 150 mil habitantes), em relação às cidades pequenas (com menos de 10 mil habitantes). Nas cidades médias (entre 10 mil e 50 mil habitantes), apenas a incidência e a mortalidade mostraram-se, significativamente, superiores.

Os resultados ainda indicam que locais com maior poluição veicular teriam maior incidência e mortalidade, porém menor letalidade. Este último resultado ainda carece de explicações. É possível que os municípios com maior densidade veicular também possuam uma infraestrutura de saúde mais adequada, o que ajudaria a reduzir a letalidade local. Além disso, temperaturas elevadas estariam associadas com maiores taxas de incidência e mortalidade, enquanto a precipitação apresentaria relação positiva com a mortalidade e a letalidade de Covid-19 (Tabela 3).

A Tabela 3 também revela que, embora os gastos com saúde possam aumentar as taxas de incidência e de mortalidade locais (possivelmente por atrair mais indivíduos

em busca de tratamento), poderiam reduzir a letalidade. Já uma oferta adequada de hospitais minimizaria tanto a mortalidade quanto a letalidade da doença. Por sua vez, a oferta de leitos e o nível de cobertura à atenção básica parecem atrair mais pessoas infectadas, aumentando a incidência local, mas sem efeitos negativos e/ou significativos sobre a mortalidade e a letalidade.

## 5. Considerações Finais

A pandemia de Covid-19, devido às medidas de contenção do vírus (que incluíam restrições econômicas e sociais), acabou gerando problemas significativamente distintos entre os municípios brasileiros. Em alguns casos, os impactos socioeconômicos foram devastadores e revelaram tanto a existência de certas desigualdades regionais quanto a necessidade de políticas específicas de combate a futuros surtos epidemiológicos da doença.

Deste modo, considerando informações sobre os 5.570 municípios brasileiros, no ano de 2020, e valendo-se de regressões via *Mínimos Quadrados Ordinários* (MQO) e *Binomiais Negativas* (BN), o presente estudo avaliou quais características municipais poderiam influenciar a intensidade local da pandemia, no que tange ao total de casos e óbitos, bem como às suas taxas de incidência, mortalidade e letalidade.

Após consultar a (recente) literatura sobre o tema e notar a escassez de estudos empíricos sobre os condicionantes municipais da Covid-19 no Brasil, verificou-se que certos indicadores de saúde e outras questões socioeconômicas, demográficas e climáticas, dos municípios, poderiam afetar a severidade local associada à Covid-19. Logo, as estimativas desta pesquisa, baseadas nos fatores supracitados, indicaram que municípios de menor porte, com clima ameno e seco, gastos adequados em saúde e bom nível educacional, população majoritariamente idosa e composta por homens, menor atividade econômica, pouca desigualdade interna, baixa poluição veicular e um bom sistema de transporte público teriam menos casos e óbitos por Covid-19. Além de revelar certas associações relativas à incidência e à mortalidade, as estimativas também indicaram que a letalidade da doença seria menor entre as cidades mais ricas, com população tipicamente adulta (entre 20-39 anos), melhor transporte público, bom nível educacional, baixos níveis de densidade populacional e de poluição veicular, maiores gastos em saúde e mais hospitais.

Embora tais resultados possam auxiliar a implementação de políticas públicas de combate aos efeitos locais da Covid-19, ressalta-se que boa parte dos mecanismos de transmissão desses fatores continuam sob debate. Ademais, o uso de dados secundários, de corte transversal (*cross-section*) e em escala municipal impõe sérias limitações ao estudo, que incluem: a dificuldade de obtenção de boas *proxies* socioeconômicas locais, a impossibilidade de controles intertemporais e a possibilidade de incorrer em *falácias ecológicas*. Portanto, novos estudos são necessários, com diferentes controles metodológicos e recortes regionais, a fim de assegurar/refutar os

efeitos aqui apresentados.

Por fim, destaca-se que os métodos utilizados nesta pesquisa permitem estabelecer apenas relações associativas (não causais) entre as características municipais testadas e as estatísticas de Covid-19. A título de exemplo, verificou-se que mais leitos poderiam aumentar a incidência local, pois (em tese) atrairiam pessoas infectadas de outras áreas. Contudo, é possível que a incidência elevada também estimule a oferta municipal de leitos, gerando um efeito bi-causal. Sobre esse tópico, dado o esforço dos municípios para atender os casos mais graves da doença (especialmente no auge da pandemia), talvez seja interessante avaliar, em estudos futuros, se a variação da oferta local de leitos contribuiu, efetivamente, para a redução das taxas de mortalidade e/ou letalidade de Covid-19.

## Referências

- Arbix, G. (2020). Ciência e Tecnologia em um mundo de ponta-cabeça. *Estudos Avançados*, 34(99):65–76.
- Auler, A. C., Cássaro, F. A., da Silva, V. O., e Pires, L. F. (2020). Evidence that high temperatures and intermediate relative humidity might favor the spread of COVID-19 in tropical climate: A case study for the most affected Brazilian cities. *Science of The Total Environment*, 729:139090.
- Cameron, A. C. e Trivedi, P. K. (2010). *Microeconometrics using STATA*. Stata Press, 2 edition.
- Cole, M. A., Ozgen, C., e Strobl, E. (2020). Air Pollution Exposure and Covid-19 in Dutch Municipalities. *Environmental & Resource Economics*, 76(4):581.
- Credit, K. (2020). Neighbourhood inequity: Exploring the factors underlying racial and ethnic disparities in COVID-19 testing and infection rates using ZIP code data in Chicago and New York. *Regional Science Policy & Practice*, 12(6):1249–1271.
- Ehlert, A. (2021). The socio-economic determinants of COVID-19: A spatial analysis of German county level data. *Socio-Economic Planning Sciences*, 78:101083.
- Firme, V. d. A. C., Ribeiro, H. M. D., e Taveira, J. G. (2022). Local characteristics and the Covid-19 pandemic: an analysis focused on the municipalities from the Brazilian state of Minas Gerais. *Economia e Sociedade*, 31(3):771–793.
- Gebhard, C., Regitz-Zagrosek, V., Neuhauser, H. K., Morgan, R., e Klein, S. L. (2020). Impact of sex and gender on COVID-19 outcomes in Europe. *Biology of sex differences*, 11(1).
- Greene, W. H. (2002). *Econometric analysis*. Pearson.

- Jinjarak, Y., Ahmed, R., Nair-Desai, S., Xin, W., e Aizenman, J. (2020). Accounting for Global COVID-19 Diffusion Patterns, January-April 2020. *Economics of disasters and climate change*, 4(3):515–559.
- Khatib, A. S. S. E. (2020). Economy versus epidemiology: an analysis of trade-off between markets and lives in COVID-19 times. *Contabilidad y Negocios*, 15(30):62–80.
- Lippi, G., Mattiuzzi, C., Sanchis-Gomar, F., e Henry, B. M. (2020). Clinical and demographic characteristics of patients dying from COVID-19 in Italy vs China. *Journal of medical virology*, 92(10):1759–1760.
- Ma, Y., Zhao, Y., Liu, J., He, X., Wang, B., Fu, S., Yan, J., Niu, J., Zhou, J., e Luo, B. (2020). Effects of temperature variation and humidity on the death of COVID-19 in Wuhan, China. *The Science of the total environment*, 724.
- Mollalo, A., Vahedi, B., e Rivera, K. M. (2020). GIS-based spatial modeling of COVID-19 incidence rate in the continental United States. *Science of The Total Environment*, 728:138884.
- MS (2024). Ministério da Saúde: COVID-19 - Painel Coronavírus/Brasil.
- Neiva, M. B., Carvalho, I., Filho, E. D. S. C., Barbosa-Junior, F., Bernardi, F. A., Sanches, T. L. M., de Oliveira, L. L., Lima, V. C., Miyoshi, N. S. B., e Alves, D. (2020). Brazil: the emerging epicenter of COVID-19 pandemic. *Revista da Sociedade Brasileira de Medicina Tropical*, 53:1–8.
- Pedersen, M. J. e Favero, N. (2020). Social Distancing during the COVID-19 Pandemic: Who Are the Present and Future Noncompliers? *Public Administration Review*, 80(5):805.
- Pirouz, B., Haghshenas, S. S., Haghshenas, S. S., e Piro, P. (2020). Investigating a Serious Challenge in the Sustainable Development Process: Analysis of Confirmed cases of COVID-19 (New Type of Coronavirus) Through a Binary Classification Using Artificial Intelligence and Regression Analysis. *Sustainability 2020, Vol. 12, Page 2427*, 12(6):2427.
- Rafael, R. d. M. R., Neto, M., Depret, D. G., Gil, A. C., Fonseca, M. H. S., e Souza-Santos, R. (2020). Efeito da renda sobre a incidência acumulada de COVID-19: um estudo ecológico. *Revista Latino-Americana de Enfermagem*, 28:e3344–e3344.
- Stojkoski, V., Utkovski, Z., Jolakoski, P., Tevdovski, D., e Kocarev, L. (2020). The socio-economic determinants of the coronavirus disease (COVID-19) pandemic. *medRxiv*, Página 2020.04.15.20066068.
- Teixeira, L. A. e de Carvalho, W. R. G. (2020). SARS-CoV-2 em superfícies: persistência e medidas preventivas: uma revisão sistemática. *J. Health NPEPS*, 5(2):e4873.



Wadhera, R. K., Wadhera, P., Gaba, P., Figueroa, J. F., Joynt Maddox, K. E., Yeh, R. W., e Shen, C. (2020). Variation in COVID-19 Hospitalizations and Deaths Across New York City Boroughs. *JAMA*, 323(21):2192–2195.

Williams, D. R. e Cooper, L. A. (2020). COVID-19 and Health Equity—A New Kind of “Herd Immunity”. *JAMA*, 323(24):2478–2480.

Wu, X., Nethery, R. C., Sabath, B. M., Braun, D., e Dominici, F. (2020). Exposure to air pollution and COVID-19 mortality in the United States: A nationwide cross-sectional study. *medRxiv*.

## Agradecimentos

Os autores agradecem aos colaboradores João Victor Alves Assunção, Gabriel Soares Gualberto e Victor Lago Rodrigues, pelo suporte no projeto “Características municipais e pandemia de Covid-19: uma análise aplicada”; aos avaliadores da Revista Brasileira de Estudos Regionais e Urbanos; à toda equipe editorial; e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais - FAPEMIG, pelo financiamento do projeto citado.

 Este artigo está licenciado com uma *CC BY 4.0 license*.