

Fatores múltiplos da Covid-19: uma análise aplicada para municípios brasileiros¹

Juliana Gonçalves Taveira²
Hilton Manoel Dias Ribeiro
Vinícius de Azevedo Couto Firme
João Victor Assunção³

Resumo

A pandemia causada pela covid-19 impactou a saúde da população e a dinâmica econômica do país. Apesar disso, o efeito da pandemia se mostrou distinto entre as regiões, especialmente entre áreas mais urbanas e povoadas. Assim, o presente estudo analisou quais características municipais afetariam os índices da doença para o ano de 2020. Como isso, surge uma demanda da análise de fatores locais que possam afetar as principais estatísticas associadas à Covid-19, como o número de casos, óbitos e taxas de incidência, mortalidade e letalidade. Dada a característica de contagem das variáveis dependentes, número total de casos e de óbitos, estimou-se os modelos de poisson e binomial negativo, em que se explicam esses índices a partir de um conjunto de variáveis dos municípios brasileiros, considerando as dimensões socioeconômicas, demográficas, saúde e de clima. Verificou-se ainda os efeitos dessas variáveis sobre as taxas de incidência de mortalidade e de letalidade da Covid-19. Entre os principais resultados tem-se que municípios com maior renda per capita e gasto per capita com saúde têm melhor probabilidade de um resultado positivo em situação de pandemia dado o efeito negativo dessas variáveis sobre o número de casos e óbitos. Ter uma maior desigualdade de renda por sua vez teve efeito positivo sobre casos e óbitos da covid, enquanto uma maior densidade populacional além de aumentar óbitos aumenta a letalidade da doença. Cidades maiores tendem a ter maior número de casos e óbitos, mas ser uma cidade muito grande reduz a letalidade da doença.

Palavras-chave: Covid-19; características municipais; Indicadores de saúde

Multiple factors of Covid-19: an analysis applied to Brazilian municipalities

Abstract

The COVID-19 pandemic has had a profound impact on both public health and the economic dynamics of the country. However, the effects of the pandemic have shown variations across regions, particularly between more urban and densely populated areas. Therefore, the present study aimed to analyze which municipal characteristics influenced disease indices for the year 2020. Consequently, there is a demand to explore local factors that could affect key COVID-19 statistics, such as the number of cases, deaths, and rates of incidence, mortality, and case fatality. Given the nature of the dependent variables as counts, specifically the total number of cases and deaths, Poisson and negative binomial models were employed to explain these indices based on a set of variables from Brazilian municipalities, considering socioeconomic, demographic, health, and climatic dimensions. Furthermore, the effects of these variables on the rates of COVID-19 incidence, mortality, and case fatality were examined. Among the primary findings, it was observed that municipalities with higher per

¹ Os autores agradecem à FAPEMIG pelo apoio no desenvolvimento desta pesquisa.

² Professora Adjunta do Departamento de Economia da UFJF-GV. Email: juliana.goncalves@ufjf.br

Professor Adjunto do Departamento de Economia da UFJF-GV. Email: hilton.manoel@ufjf.br

Professor Adjunto do Departamento de Economia da UFJF-GV. Email: vinicius.firme@ufjf.br

³ Discente no curso de Economia da UFJF-GV. Bolsista FAPEMIG. Email: joao_assuncao96@outlook.com

capita income and per capita health expenditure have a better likelihood of achieving positive outcomes during a pandemic, owing to the negative effect of these variables on the number of cases and deaths. Conversely, higher income inequality had a positive effect on the incidence of COVID-19 cases and deaths, while a higher population density, in addition to increasing the number of deaths, also raised the disease's case fatality rate. Larger cities tended to have a higher number of cases and deaths, although being excessively large reduced the disease's case fatality rate.

Keywords: Covid-19; Municipal characteristics; health indicators

Código JEL: I10; R58; C2.

Area 8 Questões urbanas e metrópoles

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, o vírus se espalhou rapidamente pelo mundo, afetando milhões de pessoas e sobrecarregando os sistemas de saúde em diversos países. A pandemia não apenas evidenciou a vulnerabilidade dos sistemas de saúde, mas também revelou desigualdades socioeconômicas e sanitárias significativas no nível local.

Neste contexto, entender os determinantes municipais da Covid-19 tornou-se uma questão fundamental para compreender a disseminação do vírus e desenvolver estratégias de controle eficazes, especialmente para combater futuras pandemias. Fatores locais, como densidade populacional, infraestrutura de saúde, características socioeconômicas e comportamentais, podem desempenhar um papel crucial na propagação do vírus e na resposta à pandemia.

O Brasil, como um dos países mais afetados pela pandemia, apresenta uma diversidade regional significativa, tornando-se um cenário propício para investigar as múltiplas variáveis neste recorte geográfico que podem afetar os indicadores da Covid-19. Dessa forma, surge uma demanda da análise de fatores locais que possam afetar as principais estatísticas associadas à Covid-19, como o número de casos, óbitos e taxas de incidência, mortalidade e letalidade. Ao compreender os determinantes municipais da Covid-19, espera-se que este estudo forneça subsídios para orientar a formulação de políticas públicas e estratégias de saúde mais direcionadas e efetivas. Além disso, os resultados podem contribuir para a construção de sistemas de vigilância epidemiológica mais robustos e para a preparação para futuras emergências de saúde pública.

Segundo dados do Ministério da Saúde, até julho de 2023 já se registrava no Brasil mais de 37,7 milhões de casos acumulados confirmados de Covid-19; 704.488 óbitos acumulados; 1,9% de taxa de letalidade e 335,2 de mortalidade. A Figura 1 apresenta o comportamento do indicador de casos novos, de 2022 a 2023.

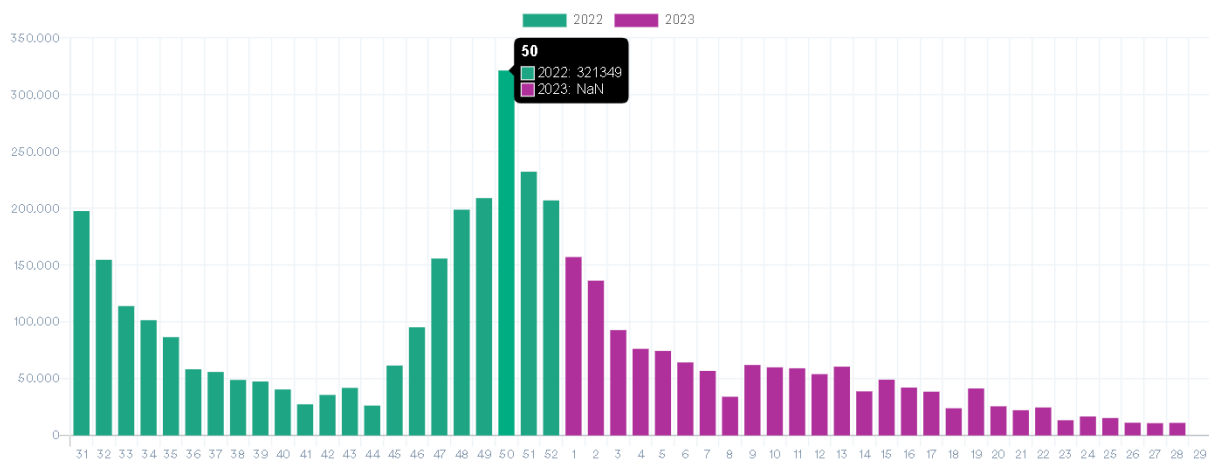


Figura 1 - Casos novos de COVID-19 por Semana Epidemiológica de notificação

Fonte: Secretarias Estaduais de Saúde. Brasil, 2020

Visando identificar os efeitos das características locais, foram estimados modelos via Mínimos Quadrados Ordinários, Poisson e Binominal Negativo, com dados cross-section, referentes aos municípios brasileiros e considerando os casos e óbitos de Covid-19 de 2020. Os resultados obtidos apontam que cidades menores, com maior gasto per capita com saúde, populações mais jovens e maior renda per capita, tendem a apresentar menos casos e óbitos

por Covid-19. Em contraste, cidades maiores, mais desiguais, caracterizadas por serem sujeitas a aglomerações, além de possuírem maior circulação de empregados, enfrentam desafios mais significativos. Cabe destacar que apesar de cidades maiores tenderem a ter maior número de casos e óbitos da doença, mas ser uma cidade muito grande reduz a letalidade da doença.

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

2. Suporte teórico e empírico

Desde o início da pandemia de Covid-19, é notável o aumento de estudos internacionais e outros voltados para o contexto brasileiro, entendendo que estas pesquisas não contribuem somente para compreensão desta pandemia já encerrada mas, principalmente, para melhorar políticas futuras, em novas pandemias. Os trabalhos foram conduzidas no intuito de compreender e abordar os diferentes aspectos relacionados à doença no país. Optou-se aqui por destacar as contribuições teóricas e empíricas que abordam a relação entre fatores socioeconômicos, demográficos, climáticos, indicadores de saúde e a Covid-19.

No que tange os fatores socioeconômicos, a pandemia e a crise econômica expuseram a nitidez da desigualdade social brasileira. Entende-se que grupos socioeconômicos, principalmente os economicamente vulneráveis, apresentam maior número de casos, com base em fatores sociais que moldam a exposição, a vulnerabilidade ao vírus e a dificuldade desses grupos em aderir às medidas de distanciamento social (BLUMENSHINE, 2008).

Mollalo et al. (2020) encontraram uma relação positiva entre desigualdade de renda e o aumento dos casos de COVID-19 nos condados dos Estados Unidos. Essa associação pode estar relacionada à concentração populacional em grandes centros urbanos, onde a desigualdade tende a ser mais acentuada. Assim, essa variável pode refletir a influência da aglomeração urbana na propagação do vírus. Outro fator que demonstra extrema relevância é a renda per capita local, estando associada ao número de casos (WILLIAMS e COOPER, 2020; WADHERA et al, 2020; COLE et al, 2020; CREDIT, 2020; RAFAEL et al, 2020; BARROS et al, 2020) e de óbitos por COVID-19 (WADHERA et al, 2020; JINJARAK et al, 2020; COLE et al, 2020).

De acordo com as pesquisas conduzidas por Stojkoski et al (2020) e Ehlert et al (2020), existe uma relação entre a propagação do vírus e os locais que apresentam uma atividade econômica mais intensa, nos quais há uma maior demanda por interação social. Essa mesma premissa pode ser entendida ao contexto do mercado de trabalho, sugerindo que regiões com uma circulação intensa de trabalhadores (BARROS et al, 2020; EHLERT, 2020) possam estar mais propensas a um maior contágio.

Em um estudo que analisou os bairros de Nova York, Wadhera et al. (2020) descobriram que as regiões com menor nível educacional apresentaram taxas mais elevadas de hospitalização e mortalidade relacionadas à COVID-19. Embora seja reconhecida a importância da educação, Ehlert (2020) destaca que seu efeito pode ter implicações contraditórias. Isso ocorre porque a educação geralmente está associada à riqueza, o que pode permitir que indivíduos mais educados tenham acesso a melhores serviços de saúde, tratamentos médicos e informações privilegiadas sobre a doença. No entanto, regiões mais ricas tendem a apresentar maior número de casos e óbitos por COVID-19.

Sobre os fatores demográficos, estudos indicam que a densidade e o porte populacional podem ter impactos sobre a quantidade de casos e de óbitos relacionadas à Covid-19 (STOJKOSKI et al, 2020; EHLERT, 2020; COLE et al, 2020; 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 áreas urbanas mais populosas, onde há uma infraestrutura médico-hospitalar mais avançada. Conforme as descobertas de Jinjark et al (2020), verifica-se que a densidade populacional exerce influência sobre a mortalidade da doença.

Por último, de acordo com as considerações de Lippi et al (2020), há uma maior suscetibilidade ao risco de óbito relacionada à Covid-19 entre o sexo masculino. Supõe-se que essa predisposição masculina a condições como hipertensão, doenças cardiovasculares e respiratórias (potencialmente associadas a um maior consumo de álcool e tabaco), possa explicar esse resultado (GEBHARD et al, 2020).

Considerando agora fatores como poluição e clima, Wu et al. (2020) e Cole et al. (2020), ao analisarem os municípios dos EUA e da Holanda, respectivamente, verificaram que regiões com atmosfera mais poluída apresentariam mais casos e óbitos por COVID-19. Ambos sugerem que a respiração prolongada de poluentes poderia enfraquecer a capacidade cardíaca e respiratória, agravando os sintomas associados ao corona-vírus. Os autores afirmam que tal cenário levaria a uma maior notificação de casos, internações e óbitos associados ao corona-vírus.

Os efeitos do clima ainda são controversos. Alguns autores indicam que altas temperaturas e maior umidade do ar aumentariam os casos e óbitos de Covid-19. Além destes, Pirouz et al. (2020) afirmam que uma maior umidade relativa aumentaria os casos (em 42 províncias da China, Japão, Coreia do Sul e Itália), enquanto a temperatura elevada os reduziria. No Brasil, cujo clima é predominantemente tropical, os locais mais quentes e úmidos poderiam estimular os indivíduos a sair de suas casas com maior frequência, aumentando o contágio pelo vírus. Por outro lado, Teixeira e Carvalho (2020) afirmam que baixas temperaturas e reduzida umidade do ar favorecem a sobrevivência do SARS-CoV-2. Portanto, a questão sobre o clima envolve descobrir qual destes argumentos seria mais relevante no local analisado.

Por fim, considerando os indicadores de saúde em si, a condição médico-hospitalar de uma região revela sua capacidade de realizar diagnósticos em massa e de lidar com epidemias mais severas. Embora uma estrutura médico-hospitalar adequada possa reduzir a mortalidade associada ao corona-vírus, é possível que os locais com melhores condições de saúde sejam acometidos por mais casos de Covid-19, visto que haveria mais testagem nestas regiões (STOJKOSKI et al., 2020). Como um número maior de casos tende a gerar mais óbitos, o efeito da infraestrutura de saúde pode divergir em estudos agregados (ecológicos) e individuais (EHLERT, 2020).

As variáveis utilizadas para medir o tamanho e a qualidade destes indicadores incluem os gastos em saúde, o número de hospitais, de médicos e enfermeiros e a cobertura de serviços essenciais de saúde (EHLERT, 2020; MOLLALO et al. 2020; STOJKOSKI et al., 2020). Outro fator relevante refere-se às comorbidades pré-existentes, ou seja, 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 corona-vírus, levando mais indivíduos a realizar testes, procurar hospitais e, inclusive, a óbito (BARROS et al., 2020; GEBHARD et al. 2020; LIPPI et al., 2020).

A presença de comorbidades e a falta de acesso adequado aos serviços de saúde são fatores que podem aumentar a vulnerabilidade das populações e o agravamento dos casos. Ainda, a disseminação de informações incorretas ou negacionistas sobre a gravidade da doença pode levar a comportamentos de risco e dificultar a implementação de estratégias eficazes de controle da pandemia. Em conjunto, esses fatores ressaltaram a importância de abordagens integradas que levaram em consideração aspectos sociais, comportamentais e sanitários para controlar a pandemia.

3. Metodologia.

Considerando o corte transversal dos dados, também conhecido como cross-section, para o ano de início da pandemia, 2020, procurou-se avaliar a relação entre um conjunto multidimensional de características municipais e os indicadores da Covid-19, conforme a equação 1 abaixo:

$$Covid_i = \alpha + \beta_1 Socio_i + \beta_2 Demo_i + \beta_3 Clima_i + \beta_4 Saude_i + \beta_5 Reg_i + \varepsilon \quad (1)$$

onde α corresponde a constante, β aos coeficientes das variáveis, $Socio_i$ ao conjunto de variáveis socioeconômicas do município i , $Demo_i$ ao conjunto de variáveis demográficas, $Clima_i$ ao conjunto de variáveis de poluição e fatores climáticos, $Saude_i$ aos indicadores de saúde, Reg_i as dummies de controle regional, e sendo ε , o termo de erro.

Esse estimador considera a função de densidade condicional de y , dado as variáveis explicativas, características municipais. As variáveis dependentes principais, isto é, o número de casos e de óbitos da Covid-19 no município, representadas por $Covid_i$, tem caráter quantitativo, discreto e não negativo, logo, são dados de contagem e o modelo de regressão linear não é adequado. Paralelamente, verificou-se ainda se os mesmos fatores municipais explicam o índice de letalidade, incidência e mortalidade da doença. Estes últimos serão estimados via mínimos quadrados ordinários.

Para possibilitar a estimação da regressão quando a variável dependente é de contagem, a literatura indica os métodos de Poisson que ajustam os modelos do número de ocorrências (contagens) de um evento. Por ser de natureza não linear e dado que a distribuição dos dados em contagem possui heterocedasticidade, que impossibilita a estimação por mínimos quadrados não lineares, a equação será estimada por meio do método de máxima verossimilhança. A fim de controlar para uma violação leve dos pressupostos utilizou-se erros padrão robustos para os parâmetros da estimação, conforme recomendado por Cameron e Trivedi (2009).

O modelo de Poisson tem o pressuposto restritivo de que a variância condicional tem que ser igual a média condicional, contudo é comum observarmos sobredispersão, ou seja, uma variância condicional superior à média condicional. Neste caso, seria mais apropriada a estimação via binomial negativo. Neste modelo, acredita-se que a variável de contagem seja gerada por um processo do tipo Poisson, mas sua variação pode ser maior do que a de um verdadeiro Poisson. O binomial negativo pode ser considerado uma generalização da regressão de Poisson, pois tem a mesma estrutura média da regressão de Poisson mas possui um parâmetro extra para modelar a sobredispersão, o parâmetro alfa.

A fim de verificar qual método melhor se ajusta à estimação, poisson ou binomial negativo, realizou-se dois testes. O teste qui-quadrado de qualidade de ajustamento, que verifica se o modelo Poisson se ajusta aos dados, e o teste de razão de verossimilhança, que testa se alfa é igual a zero, ou seja, compara o binomial negativo ao poisson. Por estes terem sido significativos, indica-se que o binomial negativo possui melhor ajustamento aos dados. Os critérios de seleção AIC e BIC também indicam o binomial negativo.

3.1 Base de dados

Para verificar se algumas características municipais aumentariam ou reduziriam os índices da Covid 19 nas regiões brasileiras construiu-se uma base de dados com variáveis retiradas de diversas fontes como o Instituto Brasileiro de Geografia e Estatística, IBGE, Relação Anual de informações Sociais, RAIS, DATASUS, Secretaria Nacional de Trânsito, Secretaria do Tesouro e Instituto do Clima.

A partir dos dados disponibilizados pelas Secretarias Estaduais de Saúde, consideramos como variáveis dependentes principais o número total de casos e número de óbitos por Covid-19 em cada município brasileiro no ano de 2020. Como medidas alternativas, calculamos as taxas de incidência, número de casos dividido pela população a cada 100 mil habitantes, taxa de mortalidade, número de óbitos dividido pela população a cada 100 mil habitantes, e a taxa de letalidade, percentual de óbitos em relação ao número de casos da doença.

Além das dummies de controle regional, as variáveis explicativas, conforme descrito na equação 1, foram divididas em 4 grupos: fatores socioeconômicos, fatores demográficos, poluição e fatores climáticos, e indicadores de saúde. Dada a relação encontrada na literatura entre os índices da Covid 19 e níveis de atividade econômica (Stojkoski et al, 2020), renda *per capita* (Williams e Cooper, 2020), desigualdade (Mollalo et al., 2020), e educação populacional (Ehlert, 2020), utilizou-se como medidas socioeconômicas: o PIB *per capita* (PIBpc) corrente de 2020, calculado pelo IBGE, como medida de renda; como proxy de atividade econômica utilizou-se o emprego, medido pelo percentual de trabalhadores formais em relação à população, retirados da RAIS; a partir da renda média dos trabalhadores formais, retirada da RAIS, calculou-se o índice de GINI⁴ por município para o ano de 2020; e como proxy da educação da população, utilizou-se o percentual de trabalhadores formais com ensino superior completo, retirados da RAIS.

Dado que a densidade e o porte populacional são importantes para explicar a doença (Stojkoski et al, 2020) e que há uma diferença de gênero nos efeitos da Covid (Lippi et al., 2020), para controlar por fatores demográficos utilizamos: o percentual de trabalhadores homens no total; percentual da população em cada faixa etária (com até 19 anos, entre 20-39, entre 40-59, e com 60 anos ou mais); densidade populacional (população dividida pela área geográfica municipal); dummies representando o porte do município (com menos de 10.000 habitantes, entre 10.000 e 50.000, entre 50.000 e 150.000, e com mais de 150.000 habitantes).

Trabalhos indicam a importância da poluição e fatores climáticos (Pirouz et al., 2020) sobre as doenças respiratórias como a Covid-19, assim, utilizou-se como controle, a médias de precipitação pluviométrica, em milímetros/mês, e de temperatura, em graus centígrados, retirados da Climate Research Unit da University of East Anglia, referente a dezembro/2011 (IPEADATA,2020); e como proxy para poluição, utilizou-se a densidade veicular (número de veículos cadastrados na Secretaria Nacional de Trânsito pela área municipal).

Dado que a estrutura de saúde do município afetaria os índices da doença, como indicadores de saúde utilizamos: gasto realizado em saúde, medido pela despesa corrente pública per capita em saúde e saneamento obtido na Secretaria do Tesouro Nacional; e como proxy para estrutura e equipamentos do setor, utilizou-se o total de postos e Unidades Básicas de Saúde e de leitos, retirados do DATASUS. Testou-se ainda como proxy de acesso à saúde privada, o percentual de indivíduos com plano de saúde privado, contudo dado o número de missings por município e que a variável não se mostrou significativa em nenhuma das estimações, optou-se por não incluí-las nos resultados.

A tabela 1 apresenta as principais estatísticas descritivas dos dados utilizados na pesquisa. Entre as variáveis relacionadas aos dados da Covid-19, em média os municípios brasileiros apresentaram 4075 casos de covid em 2020 e 113 óbitos pela doença, tendo a Covid-19 uma letalidade média de 3,72%. Os números são coerentes dado que 44% dos 5570 municípios possuem 10 mil habitantes ou menos (POPpeq), 43,79% possuem entre 10 e 50 mil habitantes (POPmed), 8,6 % entre 50 e 150 mil habitantes (POPgrd) e 3,61% mais de 150 mil (POPmtgrd). Na média, as regiões possuem cerca de 50% da população do sexo masculino e

⁴ O índice de GINI geralmente é calculado a partir dos dados da renda domiciliar per capita, contudo, dada a indisponibilidade de dados recentes por município, utilizamos como proxy para o cálculo do índice a renda média dos trabalhadores formais, disponível na RAIS.

sua maioria está na faixa de 20 a 39 anos. O gasto com saúde per capita na média dos municípios ficava em torno de R\$1.344,83

Tabela 1. Estatística descritiva dos dados

Variáveis	SIGLA	Média	Desv. Padrão	Mínimo	Máximo	
COVID-19	Casos	CSO	4075,60	21271,28	2	1114409,00
	Óbitos	OBT	113,14	854,78	0,00	43678,00
	Incidência	INC	18747,49	65812,04	6,31	1806558,63
	Mortalidade	MRT	435,46	1946,88	0,00	68009,86
	Letalidade	LET	3,72	7,46	0,00	100,00
Fatores Socioeconômicos	Renda	PIBpc	27458,30	28114,55	4924,04	591101,11
	Emprego Formal	EMPF	15,02	10,14	0,09	114,04
	Desigualdade	GINI	0,30	0,52	0,40	0,66
	Ensino Superior	EDUC	2,62	1,63	0,01	33,42
Fatores Demográficos	Gênero	GEN	0,50	0,02	0,43	0,95
	Faixa Etária	FET19-	27,81	5,46	4,15	55,78
		FET20-39	30,90	2,81	18,36	68,61
		FET40-59	25,31	3,10	10,84	36,54
		FET60+	15,98	4,84	2,46	39,30
Densidade	DENP	12,17	63,61	0,00	1459,33	
Poluição e fatores climáticos	Poluição veicular	VEIC	48,92	100,05	0,03	4178,73
	Precipitação	PREC	115,89	36,91	28,87	282,43
	Temperatura	TEMP	22,83	03,02	14,00	28,04
Indicadores de Saúde	Gasto em Saúde	GPSpc	1344,83	11240,72	0,00	779048,97
	Leitos	LTO	125,86	723,64	1,00	29764,00
	Unid. Básica	UBS	10,09	39,62	0,00	1814,00

Fonte: Elaboração própria.

Na figura 2, observa-se que tanto os casos quanto os óbitos se mostram espalhados por todo o território nacional, indicando que um efeito da pandemia em todo o território nacional. A distribuição espacial da Covid-19 nos estados brasileiros tem sido um fenômeno complexo e dinâmico desde o início da pandemia. A propagação da doença tem sido influenciada por uma série de fatores e, ao longo do tempo, observou-se uma heterogeneidade significativa na incidência e prevalência da doença, com alguns estados enfrentando surtos mais graves e outros mantendo níveis mais controlados de transmissão. Estados com grandes centros urbanos, como São Paulo e Rio de Janeiro, apresentaram maiores desafios para conter a propagação do vírus, enquanto estados com menor densidade populacional, como os da região Norte, tiveram seus próprios desafios relacionados à infraestrutura e acesso a serviços médicos. A análise detalhada da distribuição espacial da Covid-19 nos estados brasileiros tem sido fundamental para direcionar estratégias de controle da pandemia e alocar recursos de forma mais eficiente.

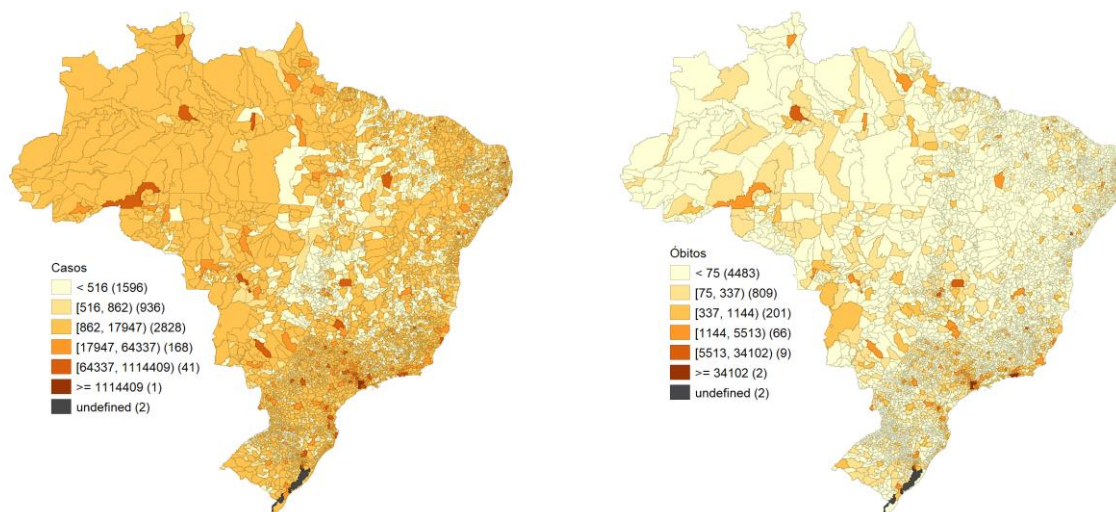


Figura 2: Número de casos e óbitos da Covid-19 em 2020.
 Fonte: Elaboração própria.

4. Resultados e análises

Com o objetivo de verificar quais características poderiam tornar os municípios mais vulneráveis ou fortes ao surgimento de uma pandemia como a Covid-19 estimou-se um modelo poisson e binomial negativo explicando o número de casos e de óbitos da doença. Dados os resultados dos testes de especificação que indicaram que o binomial negativo melhor se ajusta aos dados, a análise dos resultados irá focar nesses resultados conforme tabela 2.

Pode-se observar que ao considerar as variáveis socioeconômicas, apenas o percentual de trabalhadores com ensino superior não possui efeito sobre o número de casos e de óbitos da Covid-19. A variável de PIB *per capita* possui sinal negativo tanto para casos quanto para óbitos, o que significa que para cada aumento de uma unidade na renda *per capita* do município, a contagem de log esperada do número de casos e de óbitos causados pela doença diminui em 0,007. O percentual de trabalhadores formais e o índice de gini impactam positivamente nas variáveis relacionadas à pandemia do coronavírus. Isso indica que quanto maior a atividade econômica e o nível de desigualdade do município maior será sua vulnerabilidade diante da pandemia, ou seja, maior será o número de casos e de óbitos da doença. Tais resultados se mostram coerentes aos encontrados por autores como Stojkoski et al (2020) e Ehlert et al (2020). O resultado se mantém mesmo após incluir outras variáveis em quase todos os casos, havendo apenas uma redução da significância no caso do efeito do emprego formal sobre o número de óbitos.

Tabela 2: Fatores municipais que impactam no número de casos e óbitos pela Covid-19 em 2020. Estimado por Binomial Negativo.

	Caso				Óbito			
PIBpc	-0,0071*** (0,0010)	-0,0038*** (0,0010)	-0,0031*** (0,0008)	-0,0024*** (0,0009)	-0,0076*** (0,0013)	-0,0039*** (0,0012)	-0,0031*** (0,0010)	-0,0018* (0,0010)

EMPF	0,0445*** (0,0075)	0,0203*** (0,0070)	0,0243*** (0,0060)	0,0187*** (0,0059)	0,0319*** (0,0109)	0,0135 (0,0093)	0,0147* (0,0077)	0,0135* (0,0070)
GINI	9,6925*** (0,6492)	2,7048*** (0,9601)	2,2660*** (0,8374)	1,2563* (0,7402)	11,0673*** (0,9369)	2,2120** (1,0543)	1,9200** (0,8708)	1,1248 (0,7982)
EDUC	0,0561 (0,0341)	0,0355 (0,0315)	0,0033 (0,0263)	0,0423 (0,0270)	0,0630 (0,0474)	0,0121 (0,0351)	-0,0120 (0,0296)	0,0286 (0,0300)
GEN		-6,3805*** (1,7993)	-6,6868*** (1,5242)	-6,8092*** (1,5038)		-9,4803*** (2,0848)	-9,2172*** (1,8117)	-7,2597*** (1,7317)
FET19-		-0,0400* (0,0218)	-0,0632*** (0,0217)	-0,0534** (0,0215)		-0,0345 (0,0269)	-0,0705** (0,0285)	-0,0338 (0,0246)
FET40-59		-0,0480 (0,0332)	-0,0789*** (0,0280)	-0,0698** (0,0277)		-0,0282 (0,0392)	-0,0642* (0,0368)	-0,0444 (0,0317)
FET60+		-0,0655*** (0,0166)	-0,0624*** (0,0165)	-0,0626*** (0,0167)		-0,0658*** (0,0207)	-0,0693*** (0,0203)	-0,0472** (0,0195)
DENP		0,0006 (0,0005)	0,0006 (0,0005)	0,0006 (0,0005)		0,0016*** (0,0006)	0,0016*** (0,0006)	0,0014*** (0,0005)
POPmed		0,6434*** (0,0961)	0,6426*** (0,0815)	0,5625*** (0,0717)		0,7405*** (0,1116)	0,7100*** (0,0878)	0,6371*** (0,0789)
POPgrd		1,2819*** (0,1194)	1,3438*** (0,1088)	1,3323*** (0,1037)		1,3926*** (0,1285)	1,4565*** (0,1128)	1,4231*** (0,0982)
POPmtgrd		2,4059*** (0,1842)	2,4542*** (0,1674)	2,4036*** (0,1454)		2,7099*** (0,1907)	2,7577*** (0,1719)	2,7692*** (0,1506)
VEIC			-0,0001 (0,0002)	-0,0002 (0,0002)			-0,0002 (0,0002)	-0,0001 (0,0002)
TEMP			-0,0080 (0,0173)	0,0163 (0,0219)			-0,0104 (0,0203)	0,0216 (0,0239)
PREC			0,7872*** (0,1734)	1,0294*** (0,1692)			1,1360*** (0,1975)	1,3799*** (0,1936)
GPSpc				-0,1775** (0,0712)				-0,2627*** (0,0805)
LTO				0,0019 (0,0013)				0,0017 (0,0014)
UBS				-0,0006 (0,0008)				0,0001 (0,0012)
Constante	5,0532*** (0,2273)	13,0374*** (2,2339)	7,3148*** (2,5469)	6,1388** (2,8180)	0,9225*** (0,3173)	10,3039*** (2,6700)	1,5376 (3,1683)	-1,5407 (3,2428)
Dummies de região	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Observações	5.565	5.565	5.489	5.460	5.565	5.565	5.489	5.460

Fonte: Elaboração própria,

Nota: Erro padrão robusto entre parênteses, *** p<0,01, ** p<0,05, * p<0,1

Em relação às variáveis demográficas, observa-se que possuir um maior percentual de homens na população aumenta os casos e óbitos da Covid-19, resultado que vai ao encontro do encontrado por Lippi et al. (2020), que indicam uma maior suscetibilidade à doença dos homens. É sabido ainda que os homens são menos avessos ao risco e que por terem uma renda média no mercado de trabalho maior em relação às mulheres, estariam menos propensos a seguir ordens de restrição como as impostas pela pandemia. Possuir um maior percentual da população muito jovem em relação a ter de 20 a 40 anos ou possuir percentual maior de pessoas mais velhas que essa faixa etária, diminui a contagem de log esperada do número de casos e de óbitos causados pela Covid-19. Tal resultado era esperado, uma vez que a faixa etária de referência corresponde a que está se estabelecendo no mercado de trabalho e, portanto, estaria mais propensa a não cumprir as medidas restritivas de circulação utilizadas como principal política para conter a doença. Ser de um município maior em relação a ser um menor aumenta tanto o número de casos quanto de óbitos da Covid-19 no município, dado que as dummies de tamanho da população são positivas e a omitida se refere ser uma cidade pequena, ou seja, com menos de 10 mil habitantes. Densidade populacional parece afetar apenas o número de óbitos

pela doença, indicando que uma cidade mais densa tende a ter maior volume de óbitos na pandemia.

As variáveis climáticas e de poluição parecem não ter efeito sobre o número de casos e óbitos da doença. Entre os fatores de saúde do município, apenas o gasto com saúde parece afetar os casos e óbitos por covid, possuindo efeito negativo sobre as variáveis. Assim, um maior gasto per capita reduz o número de casos e óbitos na pandemia.

A Tabela 3 contém os resultados do modelo de estimação linear, MQO, para as variáveis de letalidade, mortalidade e incidência da covid-19 nos municípios. Como o objetivo é ver as relações entre as variáveis, o modelo de regressão simples cumpre o esperado.

Entre os fatores socioeconômicos, observa-se que diferente do número de casos e óbitos, a renda per capita dos municípios parece afetar a incidência, letalidade e mortalidade da doença apenas quando outras variáveis são omitidas. Isso indica que o efeito da renda, na verdade, está ligado a outras características do município. O percentual de pessoas educadas, por outro lado, parece afetar positivamente tanto a incidência quanto a mortalidade da doença.

Enquanto o nível de emprego formal possui efeito positivo sobre a incidência da doença, o nível de letalidade diminui com um aumento de uma unidade da variável. O emprego parece não afetar a mortalidade. Um aumento da desigualdade no município reduz a incidência e mortalidade da doença, mas não afeta a letalidade. Tal resultado vai de encontro a Ehlert (2020) que indicou que regiões ricas tendem a apresentar maior número de casos e óbitos por COVID-19.

Ser de um município maior em relação a ser um menor reduz a incidência e mortalidade da doença no município. Ter mais de 150 mil habitantes em relação a ter menos de 10 mil reduz os índices de letalidade da doença. Ter uma população maior com menos de 19 reduz a mortalidade da doença e possuir uma porcentagem maior de população com 60 ou mais aumenta a mortalidade. Um aumento da densidade populacional reduz a incidência da doença, mas aumenta a letalidade da mesma.

Um maior volume de chuva aumenta a incidência, letalidade e mortalidade da COVID-19. Já a poluição e temperatura parece afetar apenas a letalidade da doença, possuindo efeito positivo sobre a mesma, ou seja, quanto maior o volume de poluição e a temperatura das cidades, mais letal seria a doença. Tal resultado se mostra esperado, uma vez que a poluição agrava problemas pulmonares, que seriam um dos mais graves sintomas da doença, e em temperaturas mais altas as pessoas tendem a não obedecer menos as medidas restritivas de circulação. Os fatores de saúde do município parecem não afetar a incidência, letalidade e mortalidade da doença.

Tabela 3: Fatores municipais que impactam a incidência, mortalidade e letalidade da Covid-19 em 2020. Estimado por MQO.

	Incidência				Mortalidade				Letalidade			
PIBpc	0,0024*** (0,0006)	0,0000 (0,0006)	0,0001 (0,0006)	-0,0001 (0,0006)	0,0016** (0,0007)	-0,0001 (0,0007)	-0,0001 (0,0007)	-0,0001 (0,0007)	-0,0026 (0,0024)	-0,0007 (0,0024)	-0,0011 (0,0025)	-0,0008 (0,0026)
EMPF	-0,0064*** (0,0024)	0,0052** (0,0024)	0,0057** (0,0024)	0,0054** (0,0023)	-0,0112*** (0,0025)	-0,0003 (0,0027)	0,0002 (0,0027)	0,0000 (0,0027)	-0,0275*** (0,0094)	-0,0255** (0,0106)	-0,0258** (0,0107)	-0,0254** (0,0108)
GINI	-5,1070*** (0,3660)	-1,5897*** (0,3592)	-1,7406*** (0,3610)	-1,7444*** (0,3613)	-4,1419*** (0,3742)	-1,3246*** (0,3910)	-1,5254*** (0,3923)	-1,5276*** (0,3934)	-0,6571 (1,0908)	-1,6579 (1,2067)	-1,7096 (1,2156)	-1,6703 (1,2185)
EDUC	0,0655*** (0,0171)	0,0492*** (0,0160)	0,0472*** (0,0160)	0,0432*** (0,0160)	0,0690*** (0,0171)	0,0408** (0,0169)	0,0396** (0,0168)	0,0374** (0,0168)	0,0664* (0,0357)	0,0103 (0,0398)	0,0180 (0,0390)	0,0221 (0,0395)
GEN		0,3535 (0,8548)	0,4160 (0,8622)	0,2338 (0,8575)		-0,7041 (0,8243)	-0,6634 (0,8344)	-0,6970 (0,8342)		-4,4612 (3,9209)	-4,7071 (3,9425)	-4,3683 (3,9213)
FET19-		0,0033 (0,0103)	0,0030 (0,0106)	0,0004 (0,0106)		0,0275*** (0,0105)	0,0265** (0,0108)	0,0255** (0,0108)		0,0638 (0,0468)	0,0613 (0,0477)	0,0655 (0,0477)
FET40-59		-0,0014 (0,0128)	-0,0030 (0,0130)	-0,0079 (0,0131)		0,0227 (0,0138)	0,0212 (0,0141)	0,0189 (0,0142)		0,0896 (0,0582)	0,1006* (0,0608)	0,1069* (0,0612)
FET60+		0,0108 (0,0081)	0,0107 (0,0082)	0,0096 (0,0083)		0,0263*** (0,0084)	0,0247*** (0,0086)	0,0248*** (0,0087)		0,0529 (0,0399)	0,0392 (0,0393)	0,0423 (0,0398)
DENP		-0,0007* (0,0004)	-0,0008* (0,0004)	-0,0009** (0,0004)		-0,0001 (0,0004)	-0,0002 (0,0004)	-0,0003 (0,0004)		0,0018*** (0,0005)	0,0015*** (0,0004)	0,0017*** (0,0004)
POPmed		-0,4318*** (0,0333)	-0,4273*** (0,0333)	-0,4010*** (0,0356)		-0,3764*** (0,0364)	-0,3659*** (0,0362)	-0,3521*** (0,0381)		0,0789 (0,1164)	0,0977 (0,1165)	0,0712 (0,1191)
POPgrd		-0,9454*** (0,0675)	-0,9350*** (0,0674)	-0,8963*** (0,0694)		-0,8195*** (0,0696)	-0,8053*** (0,0691)	-0,7856*** (0,0706)		-0,0156 (0,2156)	-0,0130 (0,2138)	-0,0569 (0,2268)
POPmtgrd		-1,3127*** (0,1419)	-1,3024*** (0,1417)	-1,2410*** (0,1421)		-0,9565*** (0,1350)	-0,9483*** (0,1346)	-0,9058*** (0,1347)		0,8027*** (0,2541)	0,7622*** (0,2500)	0,7189*** (0,2612)
VEIC			-0,0000 (0,0001)	-0,0001 (0,0001)		0,0001 (0,0001)	0,0001 (0,0001)	0,0001 (0,0001)		0,0003* (0,0002)	0,0004* (0,0002)	0,0004* (0,0002)
TEMP			0,0027 (0,0101)	0,0021 (0,0101)		0,0077 (0,0109)	0,0076 (0,0110)	0,0076 (0,0110)		0,0685** (0,0303)	0,0692** (0,0305)	0,0692** (0,0305)
PREC			0,5539*** (0,0802)	0,5574*** (0,0802)		0,8354*** (0,0852)	0,8432*** (0,0852)	0,8432*** (0,0852)		0,9491*** (0,1301)	0,9536*** (0,1309)	0,9536*** (0,1309)
GPSpc				0,0738 (0,0458)			0,0226 (0,0453)	0,0226 (0,0453)				-0,1054 (0,1052)
LTO				-0,0009 (0,0006)			-0,0005 (0,0007)	-0,0005 (0,0007)				0,0006 (0,0036)
UBS				0,0005 (0,0006)			0,0008 (0,0007)	0,0008 (0,0007)				-0,0005 (0,0017)
Constante	10,5569*** (0,2808)	9,6102*** (0,9990)	4,4925*** (1,4274)	3,5986** (1,4340)	6,4871*** (0,1521)	4,7373*** (0,9915)	-4,2340*** (1,4806)	-3,7805** (1,4887)	4,7356* (2,4541)	2,7790 (4,3533)	-11,9204** (5,2576)	-7,5603 (5,1793)
Dummies de região	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Observações	5.565	5.565	5.489	5.460	5.565	5.565	5.489	5.460	5.565	5.565	5.489	5.460
R2	0,236	0,296	0,306	0,307	0,122	0,164	0,187	0,187	0,744	0,745	0,748	0,746

Fonte: Elaboração própria.

Nota: Erro padrão robusto entre parênteses, *** p<0,01, ** p<0,05, * p<0,1

5. Considerações finais

Além dos impactos na saúde, a pandemia da Covid-19 causou perturbações significativas nos municípios brasileiros, com as medidas de distanciamento social e restrições econômicas impostas para conter a disseminação do vírus. Essas medidas, embora necessárias, resultaram em impactos socioeconômicos devastadores, exacerbando desigualdades pré-existentes e trazendo à tona questões urgentes sobre a proteção social e o suporte aos mais vulneráveis.

Neste contexto complexo e em constante evolução, entender o comportamento e a disseminação do vírus no Brasil tornou-se uma prioridade crucial para formular estratégias efetivas de controle e mitigação dessa e de futuras pandemias. Assim, o objetivo deste trabalho foi verificar como múltiplos fatores municipais poderiam estar relacionados ao comportamento dos indicadores de casos e óbitos e as taxas de incidência, mortalidade e letalidade associadas à Covid-19. Ao indicar quais características do município o tornam mais vulneráveis à pandemia, permite-se que os formuladores de política saibam onde devem concentrar um maior volume de reforços para evitar resultados negativos similares.

De forma geral, a pesquisa acadêmica aponta que a poluição, certos indicadores de saúde (como infraestrutura, equipamentos e capital humano) e fatores socioeconômicos, demográficos e climáticos desempenham um papel significativo nos surtos da doença em regiões específicas. Entretanto, devido à recenticidade do tema, há poucos estudos disponíveis, especialmente no contexto brasileiro, e, em algumas ocasiões, os efeitos das variáveis analisadas ainda são objeto de debate e incerteza.

Entre as variáveis socioeconômicas, quanto maior a renda per capita, menor o número de casos e de óbitos. Contudo, a renda parece não afetar a incidência, letalidade e mortalidade da doença. O percentual de pessoas educadas afeta positivamente tanto a incidência quanto a mortalidade, enquanto o percentual de trabalhadores formais possui efeito positivo sobre o número de casos, de óbitos e incidência da doença. O nível de letalidade, por sua vez, diminui com um aumento de uma unidade no percentual de empregados. Um índice de gini maior aumenta o número de casos e óbitos, mas reduz a incidência e mortalidade.

Entre os fatores demográficos, possuir um maior percentual de homens aumenta os casos e óbitos da Covid-19. Já ter um maior percentual da população muito jovem em relação a ter de 20 a 40 anos ou possuir percentual maior de pessoas mais velhas que essa faixa etária, diminui o número de casos e de óbitos. A densidade populacional parece afetar positivamente o número de óbitos e letalidade da doença, mas reduz a incidência da Covid-19. Ser de um município maior em relação a ser um menor aumenta tanto o número de casos quanto de óbitos, contudo apenas ter mais de 150 mil habitantes em relação a ter menos de 10 mil reduz os índices de letalidade da doença.

As variáveis climáticas e de poluição parecem não ter efeito sobre o número de casos e óbitos da doença, mas aumentam a letalidade. Entre os fatores de saúde do município, apenas o gasto per capita em saúde de saneamento afetam os índices da Covid, reduzindo o número de casos e óbitos da pandemia. Os resultados auxiliam em termos de políticas públicas preventivas pois indicam que caso os municípios invistam em redução das desigualdades, aumentem os gastos com saúde e observem a densidade populacional, conseguiram reduzir os impactos de pandemias, como a do Coronavírus.

Referências

- ALMEIDA, E. Econometria Espacial Aplicada. Campinas, SP. Editora Alínea, 2012.
AMARAL, P. V. M.; LEMOS, M. B.; CHEIN, F. Desenvolvimento Desigual em Minas Gerais.

Cadernos BDMG, n. 14, 2007.

AQUINO, E.M.L., et al. Medidas de distanciamento social no controle da pandemia de COVID 19: potenciais impactos e desafios no Brasil. *Ciência & Saúde Coletiva*, v.25, sup.1, p. 2423-2446, 2020.

ARBIX, G. Ciência e Tecnologia em um mundo de ponta-cabeça. *Estudos Avançados*, v.34, n.99, p.65-76, 2020.

AULER A., CÁSSARO F.; SILVA V., PIRES L. 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*. v.729, 2020.

BEUGELSDIJK, S; GROOT, H. L. F.; VAN SCHAIK, A. B. T. M. Trust and economic growth: a robustness analysis. *Oxford Economic Papers*, Vol.56, p.118–134. 2004.

CAMERON, A. Colin; TRIVEDI, Pravin K. *Microeconometrics with STATA*. College Station, TX: StataCorp LP, 2009.

COLE, M.; OZGEN, C.; STROBL, E. Air Pollution Exposure and COVID-19. IZA – Institute of Labor Economics from Department of Economics, University of Birmingham, Discussion Paper No.13367. 2020. <https://ssrn.com/abstract=3628242>

CREDIT, K. Neighborhood 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*, v.12, n.6, p.1249-1271, 2020.

DATASUS – Departamento de informática do Sistema Único de Saúde do Brasil. Disponível on line em: <http://tabnet.datasus.gov.br/>. Acesso em abril/2020.

EHLERT, A. The socioeconomic determinants of COVID-19: A spatial analysis of German county level data. COVID-19 SARS-CoV-2 preprints from medRxiv and bioRxiv. version posted July 7, 2020. <https://doi.org/10.1101/2020.06.25.20140459>

FJP – Fundação João Pinheiro. Disponível on line em: <http://novosite.fjp.mg.gov.br/fjp-dados/>. Acesso em abril/2021.

GEBHARD C.; REGITZ-ZAGROSEK, V.; NEUHAUSER, H.K.; MORGAN, R.; KLEIN, S.L. Impact of sex and gender on COVID-19 outcomes in Europe. *Biology of Sex Differences*. 11(29), p.1-13, 2020.

GREENE, W. H. *Econometric Analysis*. Upper Saddle River, NJ: Prentice Hall, 2002. 802p.

HLAVAC, M. ExtremeBounds: Extreme Bounds Analysis in R. *Journal of Statistical Software*, 72(9), 1-22. 2016.

HOOVER, K. D. e PEREZ, S. J. Truth and Robustness in Cross-country Growth Regressions. *Oxford Bulletin of Economics and Statistics*, Vol. 66, Issue 5, p. 765-798. Dec. 2004. IBGE, Instituto Brasileiro de Geografia e Estatística. Disponível on line em: <http://www.ibge.gov.br>. Acesso em abril/2021.

IMPAVIDO, G. EBA: Stata module to perform extreme bound analysis. *Statistical Software Components (S347401)*, Boston College Department of Economics. 1998. IPEADATA, Instituto de Pesquisa Econômica Aplicada. Disponível on line em: <http://ipeadata.gov.br>. Acesso em abril/2021.

JHU – Johns Hopkins University & Medicine. Coronavirus Resource Center. Disponível em: <https://coronavirus.jhu.edu/>. Acesso em 17 de Abril/2021.

JINJARAK, Y., AHMED, R., NAIR-DESAI, S., XIN, W., & AIZENMAN, J. Accounting for Global COVID-19 Diffusion Patterns. *Economics of Disasters and Climate Change*, v4, p.515–559. 2020.

KHATIB, A.S.E. Economía versus epidemiología: una análise do trade-off entre mercados e vidas em tempos de COVID-19. *Contabilidad y Negocios*, (15)30, p.62-80. 2020.

LEVINE, R. & RENELT, D. A sensitivity analysis of cross-country growth regressions. *American Economic Review*, 82(4):942–63. 1992.

LIPPI, G., MATTIUZZI, C., SANCHIS-GOMAR, F., & HENRY, B. M. Clinical and

demographic characteristics of patients dying from COVID-19 in Italy versus China. *Journal of Medical Virology*, v.92. p.1759-1760. 2020.

MA, Y.; ZHAO, Y.; LIU, J.; HE, X.; WANG, B.; FU, S.; YAN, J.; NIU, J.; ZHOU, J.; LUO, B.; Effects of temperature variation and humidity on the death of COVID-19 in Wuhan, China. *Science of The Total Environment*. v.724:138226, 2020.

MAZZA, M.; MARANO, G.; LAI, C.; JANIRI, L.; SANI, G. Danger in danger: Interpersonal violence during COVID-19 quarantine. *Psychiatry Research*. v.289, July 2020.

MOLLALO, A.; VAHEDI, B.; RIVERA, K. GIS-based spatial modeling of COVID-19 incidence rate in the continental United States. *Science of The Total Environment*, v728:138884. 2020.

MS – Ministério da Saúde: COVID-19 - Painel Coronavírus/Brasil. Disponível on line em: <https://covid.saude.gov.br/>. Acesso em 17 de Abril/2021.

NEIVA, M.B., et al. Brazil: the emerging epicenter of COVID-19 pandemic. *Revista da Sociedade Brasileira de Medicina Tropical*, v.53, e20200550, 2020.

NICOLA, M., et al. The socio-economic implications of the coronavirus pandemic (COVID-19): A review. *International Journal of Surgery*. v.78, p.185-193, 2020.

PEDERSEN, M.J; FAVERO, N. Social Distancing during the COVID-19 Pandemic: Who Are the Present and Future Noncompliers? *Public Administration Review*, 80(5), p.805-814. 2020.

PEROBELLI, F. S.; FERREIRA, P. G. C.; FARIA, W. R. Análise de convergência espacial no Estado de Minas Gerais: 1975-2003. *Revista Brasileira de Estudos Regionais e Urbanos*, v.1, n.1, 2007.

PIROUZ, B.; SINA H.S.; SAMI H.S.; PIRO, P. 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*. 12(6), 2427. 2020.

PRATA, D. N.; RODRIGUES, W.; HERMEJO, P. H. Temperature significantly changes COVID-19 transmission in (sub)tropical cities of Brazil. *Science of The Total Environment*, v.729: 138862, 2020.

RAFAEL, R.; NETO, M.; DEPRET, D.; GIL, A.; FONSECA, M.; SOUZA-SANTOS, R. Efeito da renda sobre a incidência acumulada de COVID-19: um estudo ecológico. *Revista Latino Americana de Enfermagem*, v.28, e3344. 2020.

RAIS - Relação Anual de Informações Sociais: Ministério da Economia. Disponível on line em: <http://www.rais.gov.br/>. Acesso em Abril/2021.

SALA-I MARTIN, X. X. I just ran four million regressions. NBER Working Paper no. 6252. 1997.

SALARI, N., et al. Prevalence of stress, anxiety, depression among the general population during the COVID-19 pandemic: a systematic review and meta-analysis. *Global Health*. v.16, n.57, 2020.

SS/MG – Secretaria de Saúde do Estado de Minas Gerais: CORONAVÍRUS. Disponível on line em: <https://coronavirus.saude.mg.gov.br/>. Acesso em 17 de Abril/2021.

STOJKOSKI et al. The socio-economic determinants of the coronavirus disease (COVID-19) pandemic. *Cornell University - Physics & Society*. 2020. <https://arxiv.org/abs/2004.07947>

STRABELLI, T.; UIP, D. COVID-19 e o Coração. *Arquivos Brasileiros de Cardiologia*, 114(4), p.598-600. 2020.

TEIXEIRA, L.; CARVALHO, W. SARS-CoV-2 em superfícies: persistência e medidas preventivas - uma revisão sistemática. *Journal Health NPEPS*. 5(2):e4873. 2020. WADHERA, R. et al. Variation in COVID-19 hospitalizations and deaths across New York City boroughs. *Journal of the American Medical Association - JAMA*. 323(21), p.2192–2195. 2020.

WILLIAMS, D.R.; COOPER, L.A. COVID-19 and Health Equity - A New Kind of “Herd Immunity”. *Journal of the American Medical Association - JAMA*. 323(24):2478–2480. 2020.

WOOLDRIDGE, J. Quasi-likelihood methods for count data. In: Pesaran, H.; Schmidt, P. (eds). Handbook of Applied Econometrics, Blackwell, Malden, MA. p.352-406, 1996.

WOOLDRIDGE, J. Introdução à Econometria: Uma Abordagem Moderna, 4aed. Cengage Learning, São Paulo. 2010. 701p.

WU, X.; NETHERY, R.; SABATH, B.; BRAUN, D.; DOMINICI, F. Exposure to air pollution and COVID-19 mortality in the United States. medRxiv. Preprint posted April 27. 2020. <https://doi.org/10.1101/2020.04.05.20054502>.