

Características municipais e a pandemia de Covid-19: uma análise aplicada*

Vinícius de Azevedo Couto Firme[†]
Hilton Manoel Dias Ribeiro[‡]
Juliana Gonçalves Taveira[§]

RESUMO

Esta pesquisa utiliza diferentes estimadores e a técnica *Extreme Bounds Analysis* para verificar quais características locais afetariam as principais estatísticas de COVID-19 dos municípios de Minas Gerais. Constatou-se que cidades pequenas, com mais unidades básicas de saúde e populações mais jovens teriam menos casos/óbitos. Alternativamente, locais urbanos, quentes, poluídos, desiguais, com maior atividade econômica e circulação de empregados seriam mais problemáticos. A incidência/mortalidade aumentaria em cidades quentes, com elevada atividade econômica e histórico de comorbidades. Todavia, a mortalidade diminuiria entre as pessoas mais jovens/educadas. Ademais, a letalidade revelou-se menor entre os jovens e em locais pouco povoados e baixa precipitação.

Palavras-chave: COVID-19; Políticas Regionais; Determinantes socioeconômicos.

ABSTRACT

This research uses different estimators and the Extreme Bounds Analysis to verify which local characteristics would affect the main COVID-19's statistics associated with the municipalities of Minas Gerais (Brazil). It was found that small towns, with more basic-health units and youngest populations would have fewer cases/deaths. Hardest problems were verified in urban, hot, polluted and unequal places, with greater economic activity and movement of employees. Incidence/mortality would increase in hot cities, with greater economic activity and comorbidities' history. However, mortality would decrease among youngest/educated people. Furthermore, lethality would be lower among youngest people and in sparsely populated and rainless cities.

Keywords: COVID-19; Regional Policies; Socioeconomic determinants.

Código JEL: I10; R58; C2.

* Esta pesquisa foi desenvolvida pelo ECONÚCLEO, Grupo de Pesquisa em Estudos Socioeconômicos da UFJF/GV (<https://www.ufjf.br/econucleogv/>), e contou com o apoio financeiro da FAPEMIG (APQ-01255-21) e com bolsa de iniciação científica concedida pela PROPP/UFJF (Edital 01/2021).

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

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

[§] Professora Adjunta do Departamento de Economia da UFJF-GV. Email: juliana.goncalves@ufjf.edu.br.

INTRODUÇÃO

A pandemia de COVID-19, gerada pelo novo corona-vírus (SARS-CoV2),¹ iniciou-se na China/Wuhan, em 31 de dezembro/2019 (KHATIB, 2020) e, segundo Arbix (2020) já é a mais letal dos últimos 100 anos. Os dados da *Johns Hopkins University - JHU* (2021) indicam que, após 1 ano e 4 meses do caso inicial, a doença já havia atingido mais de 140 milhões de casos e cerca de 3 milhões de óbitos no mundo.

Como não há um tratamento eficaz para os sintomas da COVID-19 e as vacinas ainda não são uma realidade para a maioria da população, os especialistas têm recomendado medidas de distanciamento social para frear o contágio e evitar o colapso do sistema de saúde (AQUINO *et al*, 2020; PEDERSEN e FAVERO, 2020). Tais medidas incluem o fechamento de estabelecimentos não essenciais e escolas, restrições de viagens nacionais e internacionais e o cancelamento de festas, shows, cultos e outras atividades que gerem aglomeração (NICOLA *et al*, 2020).

Os impactos recessivos decorrentes destas políticas de distanciamento têm gerado debates entre epidemiologistas e economistas (KHATIB, 2020). Enquanto os primeiros defendem o isolamento social como a principal forma de frear o contágio, o segundo grupo preocupa-se com os impactos socioeconômicos provenientes desta prática. Para Arbix (2020), as restrições impostas pela COVID-19 geram desemprego, desigualdade de renda, falências empresariais e pobreza de forma geral. Ademais, podem estimular a violência doméstica (MAZZA *et al*, 2020) e os casos de depressão (SALARI *et al*, 2020).

Dado o dilema exposto, buscou-se verificar quais características locais poderiam afetar as principais estatísticas associadas à COVID-19 (*i.e.*: número de casos e óbitos e taxas de incidência, mortalidade e letalidade). Acredita-se que os resultados permitam a adoção de políticas específicas e regionalizadas, de modo a conter o contágio da doença (inclusive oriundo de novas variantes do vírus)² com o rigor adequado à cada local, ou seja, com maior/menor rigidez onde a doença é mais/menos danosa.

Como o Brasil é um dos epicentros desta pandemia (NEIVA *et al*, 2020), concentrando, em 17 de abril/2021, quase 10% dos casos e pouco mais de 12% dos óbitos mundiais (JHU, 2021), esta pesquisa concentrou-se nos 853 municípios de Minas Gerais.³ O Estado é economicamente representativo (3º maior PIB do Brasil; IBGE, 2021) e, segundo o Ministério da Saúde – MS (2021), tem sido responsável por, aproximadamente, 9,2% dos casos e 8,1% dos óbitos brasileiros. Ao comparar os dados do MS (2021) e do JHU (2021), nota-se que a amostra considerada representa, cerca de, 0,9% dos casos e 1% dos óbitos mundiais.⁴ Além disso, trata-se de uma região: a) bastante heterogênea, em termos socioeconômicos (PEROBELLI, FERREIRA e FARIA, 2007; AMARAL, LEMOS e CHEIN, 2007), o que permite analisar os efeitos da COVID-19 em localidades marcadamente distintas; b) com a maior concentração de municípios dentre os 26 Estados do país (cerca de 15,3% do total brasileiro), favorecendo as propriedades assintóticas dos

¹ “(...) trata-se de um betacoronavírus, do mesmo subgênero da síndrome da insuficiência respiratória aguda grave (SARS), que causou epidemia na China em 2003, e da síndrome respiratória do Médio Oriente (MERS), que causou o mesmo quadro no Oriente Médio em 2012.” (STRABELLI e UIP, 2020, p.598).

² Embora o vírus sofra mutações e, assim, gere novas epidemias, sua forma de contágio e sintomas básicos costumam se manter. Para Stradelli e Uip (2020), o modo como o SARS-CoV2 se liga às células é muito semelhante ao do SARS (China/2003) e possui 96,2% de similaridade genética com o betaCoV/bat/Yunnan, encontrado em morcegos.

³ Os primeiros casos de COVID-19 no Brasil (MS, 2021) e em Minas Gerais (Secretaria de Saúde – SS/MG, 2021) ocorreram nos dias 26 de fevereiro e 06 de março de 2020, respectivamente.

⁴ Se Minas Gerais fosse um país, seus casos (cerca de 1,293 milhão) e óbitos (mais de 30,7 mil) o colocariam na 22ª [entre Holanda (1,451 milhão) e Canadá (1,155 milhão)] e 19ª [entre Turquia (36,9 mil) e República Tcheca (28,7 mil)] posição mundial, respectivamente (SS/MG, 2021; JHU, 2021).

estimadores; c) que dispõe de uma rica base de dados municipal, com baixa incidência de *missing values*,⁵ atributo essencial às análises empíricas.

Logo, visando identificar os efeitos destas características locais, foram estimados modelos via *Minimos Quadrados Ordinários*, Poisson e Binominal Negativo, com dados *cross-section*, referentes aos municípios de Minas Gerais e considerando os casos e óbitos de COVID-19 acumulados até 21 de abril/2021.⁶ Como não há uma especificação bem definida para explicar esta pandemia, as variáveis, sugeridas pela literatura, foram avaliadas não apenas pelos estimadores supracitados, mas também via *Extreme Bounds Analysis* - EBA (LEVINE e RENELT, 1992).⁷

Os resultados indicaram que cidades pequenas, com mais unidades básicas de saúde (UBS) e populações jovens teriam menos casos e óbitos por COVID-19. Alternativamente, locais quentes, poluídos e sujeitos à aglomeração, ou seja, tipicamente urbanos, desiguais, com maior atividade econômica e circulação de empregados, seriam mais problemáticos. A incidência e a mortalidade aumentariam em municípios quentes, com maior atividade econômica e histórico de comorbidades. Todavia, a mortalidade diminuiria entre os jovens e aqueles com maior educação. Ademais, a letalidade seria menor entre os jovens e em cidades com até 150 mil habitantes e poucas chuvas.

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 usada nas estimações. Os resultados, considerações finais e referências são apresentados em sequência.

2. DETERMINANTES MUNICIPAIS DOS CASOS E ÓBITOS POR COVID-19

Como o primeiro caso de COVID-19 sequer completou 1,5 anos,⁸ ainda existem poucos estudos sobre quais aspectos locais explicariam a intensidade desta doença em regiões específicas, especialmente no Brasil. De modo geral, notou-se a prevalência de fatores socioeconômicos, demográficos, climáticos, relacionados à poluição e à alguns indicadores de saúde,⁹ conforme descrito a seguir:

a) *Fatores socioeconômicos*: acredita-se que a renda *per capita* local possa estar 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). Para Stojkoski *et al* (2020) e Ehlert *et al* (2020), a propagação do vírus seria intensificada em locais com maior nível atividade econômica, onde haveria maior necessidade de interação social.¹⁰ A mesma lógica pode ser aplicada ao mercado de

⁵ “(...) devido à criação de novos municípios e à precária coleta de dados em regiões mais pobres, raramente consegue-se trabalhar com todos os municípios brasileiros. Portanto, a fim de evitar uma base de dados com missings, optou-se por considerar apenas os 853 municípios de Minas Gerais.” (FIRME e SIMÃO FILHO, 2014, p.683).

⁶ Por se tratar de um estudo ecológico, baseado em dados secundários (cuja unidade de análise são os municípios, e não os pacientes), não foram incluídos aspectos individuais associados à COVID-19.

⁷ “*Extreme bounds analysis is useful for testing whether minor changes in the list of examined variables can fundamentally alter the conclusions of empirical research studies. (...) EBA can identify explanatory variables that are most robustly associated with the outcome variable.*” (HLAVAC, 2016, p.1-2).

⁸ Durante a elaboração desta pesquisa, a pandemia havia completado pouco mais de 1 ano e 4 meses.

⁹ “*A multitude of social and economic criteria have been attributed as potential determinants for the observed variety in the coronavirus outcome during this first wave of the pandemic. Some experts say that the hardest hit countries also had an aging population (...), or an underdeveloped healthcare system (...). Others emphasize the role of the natural environment (...).*” (STOJKOSKI *et al*, 2020, p.2).

¹⁰ “*A high level of economic activity is often based on networking (including physical networking), travel and social contacts (...).*” (EHLERT, 2020, p.10-11).

trabalho, sugerindo um maior contágio em regiões com intensa circulação de trabalhadores (BARROS *et al*, 2020; EHLERT, 2020).

Ainda nesta esfera, Mollalo *et al* (2020) encontraram uma associação positiva entre a desigualdade de renda e os casos de COVID-19 nos condados dos Estados Unidos. Como a desigualdade tende a ser maior nos grandes centros, é possível que esta variável capte algum tipo de aglomeração urbana. Além disso, Wadhera *et al* (2020), ao avaliar os bairros de Nova York, verificaram que as regiões com menores índices educacionais obtiveram taxas mais altas de hospitalização e morte por COVID-19. Embora reconheça a importância da educação, Ehlert (2020) afirma que o seu efeito pode ser contraditório. Como a educação e a riqueza apresentam correlação positiva, é possível que o indivíduo com mais educação tenha acesso à melhores hospitais, tratamentos médicos e possua vantagens informacionais sobre a doença. Porém, conforme mencionado, regiões mais ricas tendem a apresentar mais casos e óbitos por COVID-19. Portanto, pode haver diferença entre o impacto desta variável no nível individual e coletivo.

b) *Fatores demográficos*: estudos sugerem que a densidade e o porte populacional poderiam afetar o número de casos e de óbitos por COVID-19 (STOJKOSKI *et al*, 2020; EHLERT, 2020; COLE *et al*, 2020; JINJARAK *et al*, 2020). Como os casos mais severos da doença demandam acompanhamento especializado e, por vezes, intervenções de alta complexidade, é natural que os números se concentrem em cidades de maior porte, que dispõem de melhor estrutura médico-hospitalar. Além disso, Ehlert (2020) sugere que locais populosos estariam mais propensos à aglomeração e, assim, à incidência do vírus. Os resultados de Jinjarak *et al* (2020), indicam que a densidade populacional também afetaria a mortalidade desta doença. O autor ainda argumenta que regiões tipicamente urbanas, por possuírem maior risco de contágio, teriam maiores taxas de mortalidade.

Pesquisas indicam que os casos e óbitos não se distribuem de forma aleatória entre as faixas etárias. De modo geral, verifica-se que a incidência do vírus tende a ser maior entre os jovens (possivelmente pelo maior convívio social deste grupo), enquanto a mortalidade é mais elevada entre os idosos (EHLERT, 2020; JINJARAK *et al*, 2020; LIPPI *et al*, 2020; COLE *et al*, 2020). Por fim, Lippi *et al* (2020) argumentam que o risco de morte por COVID-19 tem sido maior entre os homens. Acredita-se que a predisposição masculina à hipertensão e à doenças cardiovasculares e respiratórias (possivelmente pelo maior consumo de álcool e tabaco), expliquem este resultado (GEBHARD *et al*, 2020).¹¹

c) *Poluição e fatores climáticos*: Wu *et al* (2020) e Cole *et al* (2020), ao analisar os municípios (*counties*) dos EUA e 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.¹² 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 bastante controversos. Enquanto alguns indicam que altas temperaturas e maior umidade do ar aumentariam os casos e óbitos de COVID-19 (MA *et al*, 2020; AULER *et al*, 2020),¹³ outros sugerem o oposto (PRATA *et al*, 2020;

¹¹ “Preliminary data indicate an association between comorbidities, such as chronic lung disease, hypertension, and cardiovascular disease, and severity of COVID-19. Worldwide, these morbidities are higher among men than women (...) smoking and drinking, may be contributing to the gender gaps” (GEBHARD *et al* 2020, p.7-8)

¹² “It is well known that long term exposure to pollutants such as nitrogen dioxide (NO₂), sulphur dioxide (SO₂), and fine particulate matter (PM_{2.5}) contributes to cardiovascular disease, reduces lung function, and causes respiratory illness” (COLE *et al*, 2020, p.1)

¹³ Para Auler *et al* (2020), o contágio seria maior nas cidades brasileiras com elevadas temperaturas médias (27,5 °C) e umidade relativa (próxima a 80%). Ma *et al* (2020) também encontrou uma associação positiva entre a mortalidade por corona-vírus e a temperatura na China.

WANG *et al*, 2020).¹⁴ Além destes, Pirouz *et al* (2020) afirmam que uma maior umidade relativa aumentaria os casos (em 42 províncias da China, Japão, Coréia 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.

d) *Indicadores de saúde*: 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 deste setor 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, à óbito (BARROS *et al*, 2020; GEBHARD *et al* 2020; LIPPI *et al*, 2020).

3. METODOLOGIA E BASE DE DADOS

Nesta pesquisa, buscou-se estimar o impacto das variáveis explicativas, sugeridas na Seção 2, sobre o total de casos e óbitos por COVID-19 e sobre as taxas de incidências, mortalidade e letalidade da referida doença. Assim, agrupando as k variáveis explicativas (inclusive a constante)¹⁵ em uma matriz X_{nxk} e incluindo os casos (ou óbitos, ou quaisquer taxas associadas ao SARS-CoV2) em um vetor y_{nx1} (variável dependente), pode-se estimar o impacto ($\hat{\beta}_{kx1}$) dos k elementos de X_{nxk} sobre y_{nx1} ao assumir que:

$$y_{nx1} = X_{nxk}\hat{\beta}_{kx1} + \varepsilon_{nx1} \quad (1)$$

Onde: ε_{nx1} contém os resíduos dos $n = 853$ municípios, que supõe-se independentes e identicamente distribuídos (*iid.*). Logo, bastaria usar o *Estimador de Mínimos Quadrados Ordinários* – EMQO para obter o vetor $\hat{\beta}$ (WOOLDRIDGE, 2010). Formalmente:

$$\hat{\beta}_{MQO} = (X'X)^{-1}X'y \quad (2)$$

A estimação por MQO, embora adequada às taxas de incidências, mortalidade e letalidade (cujos valores são contínuos), seria problemática aos casos e óbitos, que assumem um reduzido número de valores inteiros e não negativos (*variáveis discretas*) e

¹⁴ Prata *et al* (2020) afirmam que temperaturas maiores diminuiriam os casos nas capitais estaduais do Brasil, enquanto Wang *et al* (2020) sugere que uma maior temperatura e umidade relativa reduziriam a transmissão da doença nas principais cidades chinesas.

¹⁵ Na Tabela 1, nota-se $k = 32$, ou seja, 31 variáveis explicativas (baseadas na seção 2) mais a constante.

difícilmente teriam uma distribuição normal. Nestes casos, recomenda-se o *Estimador de Poisson – EPOI* (GREENE, 2002),¹⁶ cuja função de densidade condicional (FDC) de y , dado as X variáveis explicativas, é:

$$f(y_i|X_i'\beta) = \left[e^{-\exp(X_i'\beta)} \exp(X_i'\beta)^{y_i} \right] / y_i! \quad (3)$$

A Equação 3 não é linear e precisa ser estimada por máxima verossimilhança (GREENE, 2002). Para tanto, deve-se maximizar a função de Log-Verossimilhança, $L(\beta) = \sum_{i=1}^{n=853} [-\exp(X_i'\beta) + y_i X_i'\beta - \ln y_i!]$, para obter os β . Formalmente:

$$\frac{\partial \ln L}{\partial \beta} = \sum_{i=1}^{n=853} \{ [y_i - \exp(X_i'\beta)] X_i \} = 0 \quad (4)$$

Todavia, se a $\text{Var}(y_i|X_i'\beta) > E(y_i|X_i'\beta)$, haverá *super-dispersão* e o EPOI será inconsistente e ineficiente.¹⁷ Nestes casos, deve-se usar *Estimador Binomial Negativo – EBN*, que controla o problema ao incluir um termo adicional (ϵ_i) na média condicional ($X_i'\beta$) do EPOI. Assim, chamando $\lambda_i = \exp(X_i'\beta)$ e $u_i = \exp(\epsilon_i)$, a FDC do EBN se torna a Equação 5 e os demais passos são análogos ao EPOI (GREENE, 2002).

$$f(y_i|X_i'\beta, u_i) = \left[e^{-\lambda_i u_i} (\lambda_i u_i)^{y_i} \right] / y_i! \quad (5)$$

Como não existe uma especificação bem definida para explicar os surtos locais de COVID-19 (*i.e.*: casos, óbitos, incidência, mortalidade e letalidade), as variáveis explicativas foram avaliadas não apenas via Equação 1, valendo-se do EMQO, EPOI e EBN, mas também com base na *Extreme Bounds Analysis - EBA* (LEVINE e RENELT, 1992). A técnica EBA, ao avaliar o coeficiente (β_r), de uma variável explicativa qualquer (r), na presença de diferentes combinações das demais explicativas (S), acaba diminuindo a incerteza inerente aos modelos, reduzindo a possibilidade de que "*different studies reach different conclusions depending on what combination of regressors the investigator chooses to put into his regression.*" (HOOVER e PEREZ, 2004, p.766). Formalmente, o teste consiste em realizar estimativas, por MQO, semelhantes à Equação 6:

$$y = a + F\beta_f + \beta_r r + S\beta_s + \varepsilon \quad (6)$$

onde: y é a variável dependente; r é a variável testada, F é um grupo fixo de regressores (comum à todas as regressões)¹⁸ e S é um subconjunto de três variáveis, extraídas da matriz $X_{n \times k^*}$ (Eq. 1), onde $k^* = k - 2$ (não inclui a constante nem a variável r testada). Assim, efetua-se estimativas para todas as combinações de S (tomadas 3 a 3).¹⁹

Para Levine e Renelt (1992), a variável r é dita “robusta” se seu limite inferior (menor β_r estimado menos 2 desvios-padrões) e superior (maior β_r estimado mais 2 desvios-padrões) forem significativos (a 5% de significância) e mantiverem o mesmo sinal. Todavia, como este critério é bastante restritivo (SALA-I-MARTIN, 1997;

¹⁶ "In principle, we could analyze these data using multiple linear regression. But the preponderance of zeros and the small values and clearly discrete nature of the dependent variable suggest that we can improve on least squares and the linear model with a specification that accounts for these characteristics. The **Poisson regression model** has been widely used to study such data" (GREENE, 2002, p.740).

¹⁷ Tal hipótese pode ser testada ao regredir ($\varepsilon_t^2 - 1$) contra \hat{y}_t , após estimar o modelo de Poisson. Onde \hat{y}_t é a estimativa de y_t e $\varepsilon_t^2 = (y_t - \hat{y}_t)^2$ (WOOLDRIDGE, 1996).

¹⁸ Nesta pesquisa, não foram incluídas variáveis fixas no teste EBA. Logo: $F = \{\emptyset\}$.

¹⁹ Portanto, serão efetuadas $\{k^*/[(k^* - 3)! 3!]\}$ regressões para cada variável testada.

BEUGELSDIJK *et al*, 2004),²⁰ considerou-se um nível de significância de 15% e apenas 1 desvio-padrão no cálculo dos valores extremos. O referido teste foi disponibilizado no *software* STATA por Impávido (1998).

Operacionalmente, avaliou-se o impacto de uma variável qualquer, sobre o total de casos e óbitos por COVID-19, via EMQO, EPOI e EBN (modelos irrestritos)²¹ e com base no EBA (modelo restrito). Dado o caráter contínuo das taxas de Incidência, Mortalidade e Letalidade, apenas o EMQO e o EBA foram considerados.

3.1. Base de dados

O total de casos (*CSO*) e óbitos (*OBT*) por COVID-19, até 21 de abril/2021,²² para cada município de Minas Gerais, foi obtido na Secretaria de Saúde do Estado (SS/MG, 2021). Deste modo, calculou-se as taxas de incidência [$INC = (CSO/POP) * 100.000$] e mortalidade [$MRT = (OBT/POP) * 100.000$], a cada 100 mil habitantes, e a letalidade [$LET = (OBT/CSO) * 100$] associada à doença.²³

Com base nos fatores locais, associados à COVID-19 e descritos na seção 2, foram consideradas as seguintes variáveis explicativas:²⁴

a) *Fatores socioeconômicos:*

- Nível de atividade econômica: usou-se o PIB *per capita* (PIB_{pc}) corrente de 2018 (mais recente disponível), calculado pelo IBGE (FJP, 2021).
- Emprego formal ($EMP.F$): número de trabalhadores formais dividido pela população - valores percentuais referentes à 2019 (FJP, 2021).
- Desigualdade ($GINI$): usou-se o índice de GINI, calculado pelo IBGE com base na renda domiciliar *per capita* do censo/2010 (DATASUS, 2021).
- Educação ($EDUC$): percentual de trabalhadores com ensino superior completo (ou mais) de 2018, baseado na *Relação Anual de Informações Sociais* - RAIS (2021).

b) *Fatores demográficos:*

- Gênero (GEN): percentual de homens na população total de 2018 (RAIS, 2021).
- Faixa Etária: percentual da população com até 19 anos (referência), entre 20-39 (FET_{20-39}), 40-59 (FET_{40-59}) e 60 anos ou mais (FET_{60+}), em 2019 (FJP, 2021).
- População Urbana (URB): percentual de indivíduos que, em 2019, residiam em áreas urbanas (FJP, 2021).
- Densidade Populacional ($DEN.P$): refere-se à população de 2019 dividida pela área geográfica municipal (em Km²), disponível na FJP (2021).

²⁰ "In a critique on the application of the EBA approach to assess the robustness of growth results, Sala-i-Martin (1997) proposed to relax the criterion imposed by Leamer. His basic argument is that the EBA condition that a relationship should be significant as well as of the same sign in each and every regression equation is too strict." (BEUGELSDIJK *et al*, 2004, p.122):

²¹ Diferentemente dos modelos "irrestritos", o EBA não admite a inclusão de todas as variáveis explicativas conjuntamente.

²² Visando manter informações mensais completas, cogitou-se usar os dados acumulados até março/2021, sem incluir os 21 dias de abril/2021. Todavia, como os casos e óbitos, com e sem os valores de abril/2021, apresentaram correlação de 0.9995 e 0.9991, respectivamente, optou-se por manter os dados mais recentes, cientes de que ambas as opções não trariam alterações relevantes aos resultados.

²³ Usou-se a população municipal de 2019, calculada pelo Instituto Brasileiro de Geografia e Estatística – IBGE e disponibilizada pela Fundação João Pinheiro - FJP (2021).

²⁴ Como alguns destes fatores podem ter uma relação de bi-causalidade com a pandemia, considerou-se apenas dados anteriores à mesma. Assim, espera-se avaliar o efeito de uma variável selecionada qualquer sobre a doença, e não o contrário.

- Porte Municipal: incluiu-se *dummies*, baseadas na população de 2019 (FJP, 2021), para os municípios com até 10 mil habitantes (referência), 10-50 mil (DP_{10-50}), 50-150 mil (DP_{50-150}) e com população superior a 150 mil (DP_{150+}).

c) Poluição e fatores climáticos:

- Poluição: usou-se a densidade veicular de 2019 ($DVEI$)²⁵ e o percentual da produção oriundo do setor industrial de 2018 (IND), ambos da FJP (2021).
- Clima: refere-se às médias de precipitação pluviométrica, em milímetros/mês ($PREC$) e temperatura, em graus centígrados ($TEMP$), da *Climate Research Unit da University of East Anglia*, referentes à dezembro/2011 (IPEADATA, 2020). Nos casos faltantes, utilizou-se a informação do município mais próximo.²⁶

d) Indicadores de saúde:

- Gasto em Saúde: despesa corrente pública, *per capita*, em saúde e saneamento (GPS_{pc}) de 2019, da Secretaria do Tesouro Nacional. Nos casos omissos, usou-se o valor do ano mais recente, atualizado para 2019 via IPCA (IPEADATA, 2021).
- Estrutura e Equipamentos: total de postos e unidades básicas de saúde (UBS), unidades de pronto atendimento e socorro (PRS), hospitais ($HOSP$), leitos (LTO)²⁷ e respiradores ($RESP$), a cada 100 mil habitantes - valores de dezembro/2019 (CNES – DATASUS, 2020).
- Profissionais da área: total de médicos (clínicos gerais - $MED.C$ e pneumologistas - $MED.P$) e de enfermeiros (com formação geral - $ENF.G$ e especialistas em terapia intensiva - $ENF.TI$)²⁸ a cada 100 mil habitantes. Usou-se a média de profissionais, entre os meses de 2019, registrados no *Cadastro Nacional dos Estabelecimentos de Saúde do Brasil* – CNES (DATASUS, 2021).
- Acesso à saúde privada: percentual de indivíduos com plano de saúde privado ($P.SAU$). Dados do *Sistema de Atenção Básica: saúde da Família*, referentes a dezembro/2015 (ano mais recente) (DATASUS, 2021).²⁹
- Histórico de doenças correlatas ($D.COR$): percentual dos óbitos por neoplasias, diabetes, doenças circulatórias e respiratórias³⁰ em relação total de óbitos municipais (p/residência) – valor médio entre 2009 a 2019 (DATASUS, 2021).

A Tabela 1 contém as principais estatísticas descritivas dos dados utilizados nesta pesquisa.

Tabela 1. Estatísticas descritivas dos dados

	Variável	SIGLA	Forma do Valor	Média	Des. Pad.	Mínimo	Máximo
COVID-19	Casos	CSO	Total	1516.89	7035.63	10.00	166187.00
	Óbitos	OBT	Total	36.05	176.27	0.00	3967.00
	Incidência	INC	p/100 mil hab.	4980.00	2676.83	83.81	22361.33
	Mortalidade	MRT	p/100 mil hab.	109.28	74.26	0.00	416.44
	Letalidade	LET	% dos casos	2.30	1.43	0.00	10.00
Fatores Socioeconômicos							
	Ativ. Econômica	PIB_{pc}	R\$ de 2018: milhar	20.03	22.20	6.30	337.29
	Emprego Formal	$EMP.F$	% da população	14.87	8.95	3.14	96.46

²⁵ Divisão dos veículos cadastrados no *Departamento Nacional de Transito* pela área municipal (em Km²).

²⁶ Para tanto, usou-se o *software* GEODA que, por meio de uma matriz de pesos espaciais, permite identificar quais são os vizinhos mais próximos de cada localidade. Maiores detalhes em Almeida (2012).

²⁷ Incluiu-se os leitos hospitalares (internação e complementar) e de urgência (repouso e observação).

²⁸ $ENFG$ é igual ao número total de enfermeiros menos $ENFTI$.

²⁹ Considerou-se a população de 2015 (FJP, 2021) nos cálculos.

³⁰ CID-10, Capítulos II, IV (E10-E14), IX e X.

Desigualdade	<i>GINI</i>	Índice: 0 a 100	48.12	5.37	32.88	78.32
Educação Superior	<i>EDUC</i>	% da população	16.25	5.87	2.49	45.59
Fatores Demográficos						
Gênero	<i>GEN</i>	% da população	50.51	1.25	46.88	56.10
	<i>FET₁₉₋</i>	% da população	26.87	1.11	23.33	32.29
Faixa Etária	<i>FET₂₀₋₃₉</i>	% da população	30.27	1.33	27.47	35.26
(<i>FET</i>)	<i>FET₄₀₋₅₉</i>	% da população	25.65	0.59	23.65	27.65
	<i>FET₆₀₊</i>	% da população	17.21	1.28	11.55	20.04
Pop. Urbana	<i>URB</i>	% da população	75.76	15.50	19.35	100.00
Densidade Pop.	<i>DEN.P</i>	Habitante/Km ²	71.54	339.58	1.32	7607.03
	<i>DP₁₀₋</i>	Binária (0 ou 1)	0.56	0.50	0.00	1.00
<i>Dummies</i> de Porte	<i>DP₁₀₋₅₀</i>	Binária (0 ou 1)	0.36	0.48	0.00	1.00
(<i>DP</i>)	<i>DP₅₀₋₁₅₀</i>	Binária (0 ou 1)	0.06	0.24	0.00	1.00
	<i>DP₁₅₀₊</i>	Binária (0 ou 1)	0.02	0.14	0.00	1.00
Poluição e Fatores Climáticos						
Poluição Veicular	<i>DVEI</i>	Veículos/Km ²	38.17	256.28	0.16	6902.97
Poluição Industrial	<i>IND</i>	% da Ind. no PIB	13.34	14.15	1.90	80.80
Temperatura	<i>TEMP</i>	Graus °C	21.06	1.85	14.97	25.08
Precipitação	<i>PREC</i>	Milímetros/mês	113.39	18.74	64.91	152.57
Indicadores de Saúde						
Gasto em Saúde	<i>GPS_{pc}</i>	R\$ de 2019	953.08	385.72	417.71	3903.06
Unid. Bás. Saúde	<i>UBS</i>	p/100 mil hab.	50.42	27.97	6.53	256.08
Prontos Socorros	<i>PRS</i>	p/100 mil hab.	0.73	2.77	0.00	42.68
Hospitais	<i>HOSP</i>	p/100 mil hab.	3.07	5.19	0.00	60.64
Leitos	<i>LTO</i>	p/100 mil hab.	112.96	152.54	0.00	1030.93
Respiradores	<i>RESP</i>	p/100 mil hab.	7.68	15.47	0.00	162.64
Med. Clín. Geral	<i>MED.C</i>	p/100 mil hab.	38.27	33.65	0.00	275.39
Med. Pneumo.	<i>MED.P</i>	p/100 mil hab.	0.12	0.77	0.00	15.45
Enf. Geral	<i>ENF.G</i>	p/100 mil hab.	56.74	38.16	0.00	332.01
Enf. Terap. Intens.	<i>ENF.TI</i>	p/100 mil hab.	0.08	0.68	0.00	12.37
Plano Saúde Priv.	<i>P.SAU</i>	% da população	4.98	6.29	0.00	51.74
Doença Correlata	<i>D.COR</i>	% dos óbitos totais	58.93	7.35	37.21	76.53

Fonte: Elaboração própria dos autores.

4. ANÁLISE DOS RESULTADOS

As estimativas irrestritas, via MQO, revelam que as variáveis utilizadas possuem um baixo poder explicativo sobre a letalidade de COVID-19 ($R^2 \cong 0.08$), mas melhoram ao explicar a mortalidade ($R^2 \cong 0.19$), a incidência ($R^2 \cong 0.27$) e o total de casos e óbitos (ambos com $R^2 \cong 0.78$). Dentre todas as estimativas, apenas a faixa etária entre 40-59 anos (FET_{40-59}) e o percentual de indivíduos com plano de saúde ($P.SAU$) não se mostraram significativas. Todavia, no caso de FET_{40-59} , isto apenas implica que não há diferença relevante (em termos de casos, óbitos, incidência, mortalidade e letalidade) entre esta faixa e a FET_{60+} (TABELA 2).

Dado o caráter discreto dos casos (CSO) e óbitos (OBT) e o problema de *super-dispersão*, verificado em todos os modelos de Poisson (POI), recomenda-se o uso dos estimadores Binomiais Negativos (B.N.) em ambos os casos. Além disso, as variáveis menos significativas, de cada modelo, foram excluídas de modo a minimizar o critério AIC. Tal procedimento melhorou as especificações iniciais e permitiu identificar algumas variáveis relevantes (e.g.: um maior número de leitos, LTO , que parecia não afetar a mortalidade em MQO⁽¹⁾, poderia reduzi-la no MQO⁽²⁾). Portanto, considerando o estimador adequado à cada caso e os modelos com os menores AIC, assinalados pelo sobrescrito (2), verificou-se que (TABELA 2):

a) Fatores socioeconômicos: cidades com maior atividade econômica (PIB_{pc}) tenderiam a ter mais casos, óbitos, incidência e mortalidade por COVID-19. Já locais com um alto percentual de empregos formais ($EMP.F$) teriam casos, incidência e letalidade elevados. A desigualdade ($GINI$) está associada a mais casos e óbitos, enquanto a educação ($EDUC$) poderia reduzir os óbitos, a mortalidade e a letalidade da doença.

b) Fatores demográficos: municípios com maior percentual de homens (GEN) tenderiam a ter menos casos e óbitos. Já aqueles com população predominantemente jovem (FET_{19-}) teriam menos óbitos, mortalidade e letalidade por corona-vírus. Todavia, indivíduos entre 20-39 anos (FET_{20-39}), que tendem a possuir maior convívio social, inflariam o número de casos e óbitos de suas localidades. Populações tipicamente urbanas (URB) enfrentariam mais casos, óbitos, incidência e mortalidade por COVID-19.³¹ A densidade populacional ($DEN.P$) também seria nociva, aumentando os casos, óbitos e a letalidade da doença. Ademais, verificou-se que as cidades com mais de 150 mil habitantes (DP_{150+}) seriam propensas a ter mais casos e óbitos e seriam acometidas por maiores taxas de mortalidade e letalidade.

c) Poluição e fatores climáticos: cidades com maior poluição veicular ($DVEI$) possivelmente enfrentariam mais casos e óbitos. Já as localidades com perfil industrial (IND) poderiam ter problemas com os casos e a incidência de COVID-19. Temperaturas ($TEMP$) elevadas foram associadas com mais casos, óbitos, incidência, mortalidade e letalidade. Embora os resultados indiquem que cidades chuvosas ($PREC$) tenham menos casos e baixa incidência, tal condição parece aumentar os óbitos e a letalidade da doença.

d) Indicadores de saúde: localidades que mantêm maiores gastos públicos em saúde (GPS_{pc}) revelaram-se mais efetivas em reduzir a letalidade do corona-vírus. Quanto à questão estrutural, as unidades básicas (UBS) parecem conter os casos e óbitos, enquanto os hospitais ($HOSP$) diminuem os óbitos. Além disso, cidades com mais leitos (LTO) enfrentariam menores taxas de mortalidade. Embora as estimativas indiquem que os locais com mais enfermeiros, especialistas em terapia intensiva ($ENF.TI$), encontrariam uma menor letalidade da doença, os demais resultados, associados à “equipe de saúde”, revelaram-se adversos. Em geral, notou-se que cidades com mais pneumologistas ($MED.P$) teriam maior mortalidade, enquanto àquelas com mais enfermeiros ($ENF.G$) teriam mais óbitos e maior letalidade. Por fim, municípios com histórico mais severo de doenças correlatas à COVID-19 ($D.COR$) apresentariam mais casos, óbitos, incidência e mortalidade.

³¹ Embora as estimativas por MQO indiquem um efeito negativo de URB sobre os casos e óbitos, reforça-se que, nestes casos, o modelo adequado é o Binomial Negativo (B.N.), cujos coeficientes são positivos.

Tabela 2. Estimativas irrestritas dos fatores associados ao COVID-19

	Casos						Óbitos						Incidência		Mortalidade		Letalidade	
	MQO ⁽¹⁾	MQO ⁽²⁾	POI ⁽¹⁾	POI ⁽²⁾	B. N. ⁽¹⁾	B. N. ⁽²⁾	MQO ⁽¹⁾	MQO ⁽²⁾	POI ⁽¹⁾	POI ⁽²⁾	B. N. ⁽¹⁾	B. N. ⁽²⁾	MQO ⁽¹⁾	MQO ⁽²⁾	MQO ⁽¹⁾	MQO ⁽²⁾	MQO ⁽¹⁾	MQO ⁽²⁾
<i>PIB_{pc}</i>	0.0002	NS	3.5e-06**	3.5e-06**	3.1e-06*	2.8e-06*	-0.00002	NS	5.2e-06***	5.1e-06***	3.8e-6**	3.8E-06***	0.0207*	0.0225**	0.0004**	0.0004***	3.0e-06	3.1e-06
<i>EMP.F</i>	61.980**	73.153***	0.0167***	0.0167***	0.0112***	0.0112***	1.2528*	1.1274**	0.0048	0.049	-0.0009	NS	35.706*	39.366**	-0.4388	NS	-0.0293***	-0.0319***
<i>GINI</i>	3950.3***	3950.4**	0.8824	0.8814	0.7280*	0.7329*	112.97**	119.29***	0.9778	0.9416	1.0886**	1.0772**	-417.58	NS	21.303	NS	0.3088	NS
<i>EDUC</i>	24.972	31.000	0.0025	0.0025	-0.0054	-0.0057	0.3055	NS	-0.0039	-0.0041	-0.0196***	-0.0193***	-8.0938	NS	-1.5189***	-1.4979***	-0.0266***	-0.0251***
<i>GEN</i>	10.127	NS	-0.0399	-0.0398	-0.0408**	-0.0397**	-0.3012	NS	-0.0542	-0.0519	-0.0549**	-0.0545**	-90.032	NS	-3.6988	-3.6057	0.0070	NS
<i>FET₁₉₋</i>	-526.66**	-439.90**	-0.2466***	-0.2475**	0.0547	0.0545	-16.104**	-13.919**	-0.3810***	-0.3859***	-0.0891*	-0.0890*	26.856	NS	-13.284***	-14.169***	-0.3184***	-0.2951***
<i>FET₂₀₋₃₉</i>	-103.23	NS	0.2699***	0.2697***	0.4158***	0.4201***	-3.1567	NS	0.3168***	0.3152***	0.4166***	0.4188***	129.32	NS	2.7632	NS	-0.0632	NS
<i>FET₄₀₋₅₉</i>	-280.79	NS	0.0017	NS	-0.1118	-0.1226	-4.2131	NS	-0.0611	-0.0658	-0.1583	-0.1565	19.277	NS	-8.2304	-11.637	-0.2131	-0.1925
<i>FET₆₀₊</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>URB</i>	-17.050**	-13.398*	0.0057**	0.0058**	0.0046***	0.0045**	-0.5552***	-0.5770***	0.0022	0.0025	0.0034	0.0036*	21.998***	24.663***	0.2869	0.3686**	-0.0026	NS
<i>DEN.P</i>	0.8926	NS	-0.0001	-0.0001	0.0002*	0.0002*	0.0730	0.0725	0.0000	0.0000	0.0002**	0.0002*	-0.2716	NS	0.0027	NS	0.0002	0.0001*
<i>DP₁₀₋</i>	-16115***	-16378***	-1.7256***	-1.7262***	-1.7570***	-1.7555***	-455.65***	-445.10***	-1.4860***	-1.4870***	-1.7950***	-1.8203***	171.77	NS	-19.702	-47.471***	-0.6756*	-0.3450
<i>DP₁₀₋₅₀</i>	-15523***	-15893***	-0.8836***	-0.8843***	-1.1711***	-1.1695***	-446.35***	-437.24***	-0.7811***	-0.7823***	-1.2317***	-1.2549***	326.55	NS	-18.714	-42.451***	-0.6982**	-0.4482*
<i>DP₅₀₋₁₅₀</i>	-13269**	-13769***	-0.5761***	-0.5759***	-0.4028	-0.4023	-414.52***	-410.93***	-0.6758***	-0.6753***	-0.6057***	-0.6170***	957.90	857.62**	-13.268	-24.635*	-0.5560*	-0.4833*
<i>DP₁₅₀₊</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>DVEI</i>	16.697***	17.646***	0.0005***	0.0005***	0.0002**	0.0002**	0.3312***	0.3337***	0.0004***	0.0004***	0.0002**	0.0002**	0.2236	NS	-0.0003	NS	-0.0002	NS
<i>IND</i>	8.0902	NS	0.0023	0.0023	0.0043**	0.0042**	0.0797	NS	-0.0014	-0.0014	0.0027	0.0026	15.828	19.189**	0.2382	NS	0.0002	NS
<i>TEMP</i>	104.31	NS	0.0696**	0.0695**	0.0312*	0.0296*	4.4268**	4.2927***	0.1229***	0.1172***	0.0765***	0.0748***	136.94*	139.47*	7.6878***	6.1902***	0.0857**	0.0794**
<i>PREC</i>	-15.752*	-20.879***	-0.0066**	-0.0066**	-0.0033	-0.0035*	-0.1705	-0.1897	0.0008	NS	0.0041*	0.0042*	-24.186***	-24.465***	0.2011	NS	0.0128**	0.0137***
<i>GPS_{pc}</i>	0.2406	NS	0.0001	0.0001	-0.0001	NS	-0.0040	NS	-0.0001	-0.0001	-0.0002	-0.0002	0.6398	NS	-0.0005	NS	-0.0004**	-0.0004**
<i>UBS</i>	-11.584**	-9.9621**	-0.0094***	-0.0094***	-0.0027**	-0.0028***	-0.2838***	-0.02793***	-0.0099**	-0.0100***	-0.0035***	-0.0036***	-4.9626	-4.4896	-0.0949	NS	-0.0009	NS
<i>PRS</i>	-91.405*	-91.450*	-0.0080	-0.0080	0.0011	NS	-1.8582*	-1.8792*	0.0065	0.0067	0.0067	NS	-15.132	NS	0.9186	NS	0.0342*	0.0327
<i>HOSP</i>	-24.039	-18.236*	0.0119	0.0119	-0.0095	-0.0092	-0.8203	-0.6916**	0.0078	0.0082	-0.0096	-0.0102**	-10.289	NS	0.0251	NS	0.0139	NS
<i>LTO</i>	0.0933	NS	-0.0008*	-0.0008*	0.0004	0.0003	0.0080	NS	-0.0009*	-0.0009**	-0.0001	NS	0.2331	NS	-0.0520	-0.0433**	-0.0010*	-0.0006
<i>RESP</i>	30.452**	30.894**	0.0007	0.0007	0.0005	NS	0.8049**	0.8195**	0.0018	0.0018	0.0014	NS	-3.7753	NS	0.1014	NS	0.0018	NS
<i>MED.C</i>	3.2289	3.9175	0.0015	0.0015	-0.0006	NS	0.1374*	0.1361*	0.0030**	0.0030**	0.0000	NS	-4.0221	NS	-0.0844	NS	-0.0009	NS
<i>MED.P</i>	306.50	278.74	0.1021***	0.1021***	0.0466	0.0482	7.8986	7.9296	0.0860***	0.0863***	0.0328	NS	196.57*	188.40*	1.6585	NS	-0.0473	NS
<i>ENF.G</i>	2.9786	NS	-0.0001	-0.0001	0.0003	NS	0.1234	0.1232	0.0011	0.0011	0.0012	0.0013*	-1.2922	NS	0.1127	NS	0.0032	0.0031*
<i>ENF.TI</i>	107.45	NS	0.0069	0.0069	-0.0058	NS	0.6173	NS	-0.0024	NS	-0.0300	NS	26.200	NS	-0.6210	NS	-0.0472	-0.0643**
<i>P.SAU</i>	-10.544	NS	-0.0005	-0.0005	0.0019	NS	-0.5376	-0.5291	-0.0029	-0.0029	-0.0001	NS	14.294	NS	-0.0744	NS	-0.0022	NS
<i>D.COR</i>	9.093	NS	0.0049	0.0049	0.0139***	0.0140***	-0.0052	NS	0.0005	NS	0.0138***	0.0137***	103.14***	105.07***	2.1695***	2.2507***	0.0055	NS
CTE	37152.4	28469.6***	6.0739	6.1469*	-3.3446	-3.2131	1004.6	724.76***	5.4963	5.9133	-2.7104	-2.8027	-4761.0	-4384.4*	481.82	744.40***	16.178**	13.452**
R ²	0.783	0.782	0.944	0.944	0.151	0.151	0.778	0.778	0.916	0.916	0.239	0.239	0.272	0.264	0.189	0.180	0.080	0.076
AIC	16288.2	16267.7	235381.5	235379.7	11827.8	11815.5	10020.1	100001.1	9634.6	9630.2	5633.1	5620.1	15673.4	15645.1	9649.8	9625.0	3013.6	2991.7

Notas: a) *p*-valor: * <0.10; ** <0.05; *** <0.01; b) usou-se a matriz robusta de White em todas as estimativas; c) O problema da *superdispersão* foi detectado em todos os modelos de Poisson; d) NS = não significativo e EXC = variável excluída (referência); e) as células *hachuradas* indicam alternância de sinais significativos.

Fonte: Elaboração própria com base no *software* STATA 14.

Tabela 3. Análise restrita das variáveis associadas ao COVID-19: Teste EBA

	Casos - CSO		Óbitos - OBT		Incidência - INC		Mortalidade - MRT		Letalidade - LET	
	Teste Sig. (Min. a Máx.)	Teste Sinal (Min. a Máx.)	Teste Sig. (Min. a Máx.)	Teste Sinal (Min. a Máx.)	Teste Sig. (Min. a Máx.)	Teste Sinal (Min. a Máx.)	Teste Sig. (Min. a Máx.)	Teste Sinal (Min. a Máx.)	Teste Sig. (Min. a Máx.)	Teste Sinal (Min. a Máx.)
<i>PIB_{pc}</i>	0.027 a 0.047	0.009 a 0.066	0.0007 a 0.0008	0.0002 a 0.0013	0.0218 a 0.0457	0.0150 a 0.0525	0.0005 a 0.0006	0.0004 a 0.0007	NS	NS
<i>EMP.F</i>	66.46 a 318.50	18.07 a 366.89	1.836 a 7.702	0.606 a 8.932	57.940 a 122.800	41.775 a 138.965	1.229 a 1.859	0.938 a 2.150	NS	NS
<i>GINI</i>	11100.0 a 22500.0	7246.5 a 26353.5	284.40 a 540.80	188.98 a 636.22	NS	NS	NS	NS	NS	NS
<i>EDUC</i>	116.80 a 245.30	66.24 a 295.86	4.372 a 5.873	3.171 a 7.074	-91.640 a -63.550	-113.332 a -41.858	-2.721 a -1.775	-3.090 a -1.406	NS	NS
<i>GEN</i>	-1610.00 a -511.60	-1933.24 a -188.36	-40.440 a -12.840	-48.544 a -4.736	-460.00 a -278.40	-530.70 a -207.61	-11.160 a -8.213	-12.830 a -6.543	NS	NS
<i>FET₁₉₋</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>FET₂₀₋₃₉</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>FET₄₀₋₅₉</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>FET₆₀₊</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>URB</i>	41.08 a 119.10	15.22 a 144.96	1.054 a 2.943	0.408 a 3.589	26.440 a 57.920	19.683 a 64.677	0.799 a 1.337	0.694 a 1.442	NS	NS
<i>DEN.P</i>	5.747 a 15.740	2.800 a 18.687	0.2090 a 0.3980	0.1555 a 0.4515	NS	NS	NS	NS	NS	NS
<i>DP₁₀₋</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>DP₁₀₋₅₀</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>DP₅₀₋₁₅₀</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>DP₁₅₀₊</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>DVEI</i>	12.940 a 21.470	10.492 a 23.918	0.2310 a 0.5140	0.1455 a 0.5995	NS	NS	NS	NS	NS	NS
<i>IND</i>	41.510 a 80.480	22.566 a 99.424	1.138 a 1.317	0.685 a 1.770	28.250 a 64.250	16.898 a 75.602	0.738 a 1.009	0.580 a 1.167	NS	NS
<i>TEMP</i>	NS	NS	NS	NS	228.80 a 444.20	124.07 a 548.93	6.436 a 12.270	2.714 a 15.992	NS	NS
<i>PREC</i>	84.980 a 92.690	63.619 a 114.051	1.752 a 2.405	1.218 a 2.939	-31.840 a 49.230	45.874 a 63.264	0.573 a 1.594	0.215 a 1.952	0.0112 a 0.0212	0.0087 a 0.0237
<i>GPS_{pc}</i>	1.681 a 3.815	0.731 a 4765	0.0453 a 0.0897	0.0218 a 0.1132	0.928 a 1.916	0.488 a 2.356	0.030 a 0.035	0.022 a 0.043	NS	NS
<i>UBS</i>	-73.250 a -21.570	-86.419 a -8.401	-1.799 a -0.564	-2.126 a -0.237	-24.850 a -13.380	-29.342 a -8.888	-0.510 a -0.403	-0.601 a -0.312	NS	NS
<i>PRS</i>	NS	NS	NS	NS	NS	NS	NS	NS	NS	NS
<i>HOSP</i>	-398.00 a -189.70	-505.09 a -82.61	-9.988 a -4.723	-12.659 a -2.052	NS	NS	NS	NS	NS	NS
<i>LTO</i>	4.022 a 18.580	-0.251 a 22.853	0.1080 a 0.4600	-0.0002 a 0.5682	2.475 a 4.198	1.699 a 4.974	NS	NS	NS	NS
<i>RESP</i>	76.16 a 179.50	52.30 a 203.36	1.906 a 4.525	1.308 a 5.123	24.150 a 32.250	17.519 a 38.881	0.679 a 0.779	0.535 a 0.923	NS	NS
<i>MED.C</i>	18.660 a 51.430	8.883 a 61.207	0.511 a 1.279	0.265 a 1.525	11.240 a 15.150	7.681 a 18.709	NS	NS	NS	NS
<i>MED.P</i>	845.90 a 1868.00	544.22 a 2169.68	20.640 a 47.260	13.034 a 54.866	NS	NS	NS	NS	NS	NS
<i>ENF.G</i>	18.140 a 49.620	9.944 a 57.816	0.441 a 1.282	0.237 a 1.486	NS	NS	0.274 a 0.302	0.230 a 0.346	NS	NS
<i>ENF.TI</i>	899.70 a 2756.00	317.15 a 3338.55	23.840 a 66.530	9.421 a 80.949	NS	NS	NS	NS	NS	NS
<i>P.SAU</i>	NS	NS	NS	NS	60.010 a 81.340	42.258 a 99.092	NS	NS	NS	NS
<i>D.COR</i>	NS	NS	NS	NS	47.38 a 110.30	31.21 a 126.47	1.652 a 3.340	1.305 a 3.687	NS	NS

Notas: **a)** Teste Sig. → teste de significância dos valores extremos, com 85% de confiança; **b)** Teste Sinal. → teste de alternância dos sinais extremos. Usa-se $\beta^{max} + 1DP$ e $\beta^{min} - 1DP$, onde DP é o desvio padrão dos β estimados para cada variável testada; **c)** NS = não significativo (*i.e.*: p -valor > 0.15) e EXC = variável excluída; **d)** as células *hachuradas* indicam alternância de sinais em relação aos valores da Tabela 2.

Fonte: Elaboração própria com base no *software* STATA 14.

Como é possível que alguns dos sinais e significâncias, obtidos na Tabela 2, se alterem após a inclusão ou exclusão de certas variáveis explicativas, buscou-se assegurar a validade das inferências efetuadas por meio do teste denominado *Extreme Bounds Analysis* – EBA (TABELA 3). Após 1540 estimações, para cada variável explicativa considerada,¹ a técnica EBA permitiu identificar as não significativas (NS) e aquelas com duvidade de sinal (tachadas com “X”). Assim como na Tabela 2, o teste EBA (TABELA 3) indica que os prontos-socorros (*PRS*) não seriam significantes em nenhum dos modelos considerados. Alternativamente, o efeito da precipitação (*PREC*) sobre a incidência, que seria negativo na Tabela 2, revelou-se duvidoso no EBA (*i.e.*: oscilaria entre positivo ou negativo, conforme a especificação). Ademais, o fato de apenas *PREC* explicar a letalidade por COVID-19 (LET), de forma significativa, reforça o baixo poder explicativo associado à esta taxa e incita novos estudos sobre o tema (TABELA 3).

Ao comparar as estimações restritas e irrestritas, percebe-se que os sinais indicados na técnica EBA (TABELA 3) divergiram dos modelos irrestritos (TABELA 2) apenas quanto ao impacto da Educação (*EDUC*) sobre os óbitos e no efeito da precipitação (*PREC*) sobre os casos de COVID-19. Portanto, com exceção destes dois casos, as demais análises, previamente efetuadas, permanecem válidas. Ainda assim, é possível aumentar a credibilidade das inferências ao compilar, na Tabela 4, as estimativas significativas e seus sinais, obtidos via EBA e via modelos irrestritos.²

Com base nos resultados da Tabela 4, pode-se afirmar, com *elevada confiança*,³ que haveria menos casos de COVID-19 em cidades com até 50 mil habitantes (DP_{10-} e DP_{10-50}) ou que possuam mais unidades básicas de saúde (*UBS*). Assim, os surtos da doença ficariam concentrados em locais com maior circulação de empregados (*EMP.F*), população tipicamente urbana (*URB*) e alto índice de poluição veicular (*DVEI*). Além disso, há *boa chance* de que cidades chuvosas (*PREC*) apresentem menos casos, enquanto as mais desiguais (*GINI*) e com maior atividade econômica (PIB_{pc}) teriam mais notificações.

Com *elevada confiança*, acredita-se que os óbitos sejam menos frequentes em populações jovens (FET_{19-}), em cidades de pequeno e médio porte (DP_{10-} , DP_{10-50} e DP_{50-150}) e naquelas com mais unidades básicas de saúde (*UBS*). Todavia, a poluição veicular (*DVEI*) tenderia a aumentar os óbitos. Além disso, há *boas chances* de que os óbitos sejam maiores em municípios desiguais (*GINI*), com maior atividade econômica (PIB_{pc}), quentes (*TEMP*) e com alta concentração de médicos (*MED.C*).

Quanto às taxas, há *elevada confiança* de que locais com maior atividade econômica (PIB_{pc}), circulação de empregados (*EMP.F*), urbanos (*URB*), quentes (*TEMP*), com menos chuvas (*PREC*) e histórico mais severo de doenças correlatas (*D.COR*) sofreriam com uma maior incidência de COVID-19. Já a mortalidade, seria menor entre os jovens (FET_{19-}) e em locais com maior nível educacional (*EDUC*). Porém, tenderia a aumentar nas cidades com maior atividade econômica (PIB_{pc}), quentes (*TEMP*) e com histórico de doenças correlatas (*D.COR*). Quanto à letalidade, o problema seria menor nas cidades de pequeno e médio porte (DP_{10-50} e DP_{50-150}) e entre os jovens (FET_{19-}), mas poderia aumentar em locais chuvosos (*PREC*). Por fim, há *boas chances*

¹ Esta pesquisa contou com 31 variáveis explicativas (TABELA 1). Todavia, as faixas etárias (*FET*) e as *dummies* de porte (*DP*), cujo somatório é 1, foram excluídas (EXC) do teste EBA a fim de evitar a perfeita colinearidade com a constante do modelo. Assim, restaram 23 variáveis no teste. Logo, $k^* = 22$ e tem-se um total de $\{22! / [(22 - 3)! 3!]\} = 1540$ estimações para cada variável *r* testada (rever Eq. 6).

² Nos casos e óbitos, considerou-se as 6 estimativas irrestritas (TABELA 2) e os coeficientes, de mínimo e máximo, obtidos via EBA (TABELA 3). Quanto às taxas, usou-se as 2 estimativas irrestritas e os 2 coeficientes (mínimo e máximo) do EBA.

³ O termo “*elevada confiança*” foi atribuído às variáveis significativas em 100% das estimativas, enquanto a “*boa chance*” refere-se às significativas entre 75% e 99% dos casos.

de que a incidência e a mortalidade sejam maiores em regiões com perfil industrial (*IND*) e tipicamente urbanas (*URB*), respectivamente.

Tabela 4. Análise final das variáveis associadas ao COVID-19

	Casos			Óbitos			Incidência			Mortalidade			Letalidade		
	Teste Sig.	Sinal		Teste Sig.	Sinal		Teste Sig.	Sinal		Teste Sig.	Sinal		Teste Sig.	Sinal	
		+	-		+	-		+	-		+	-		+	-
<i>PIB_{pc}</i>	6/8	6/6	0/6	6/8	6/6	0/6	4/4	4/4	0/4	4/4	4/4	0/4	0/4	NS	NS
<i>EMP.F</i>	8/8	8/8	0/8	4/8	4/4	0/4	4/4	4/4	0/4	2/4	2/2	0/2	2/4	0/2	2/2
<i>GINI</i>	6/8	6/6	0/6	6/8	6/6	0/6	0/4	NS	NS	0/4	NS	NS	0/4	NS	NS
<i>EDUC</i>	2/8	2/2	0/2	4/8	2/4	2/4 ^(a)	2/4	0/2	2/2	4/4	0/4	4/4	2/4	0/2	2/2
<i>GEN</i>	4/8	0/4	4/4	4/8	0/4	4/4	2/4	0/2	2/2	2/4	0/2	2/2	0/4	NS	NS
<i>FET₁₉₋</i>	4/6	0/4	4/4	6/6	0/6	6/6	0/2	NS	NS	2/2	0/2	2/2	2/2	0/2	2/2
<i>FET₂₀₋₃₉</i>	4/6	4/4	0/4	4/6	4/4	0/4	0/2	NS	NS	0/2	NS	NS	0/2	NS	NS
<i>FET₄₀₋₅₉</i>	0/6	NS	NS	0/6	NS	NS	0/2	NS	NS	0/2	NS	NS	0/2	NS	NS
<i>FET₆₀₊</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>URB</i>	8/8	6/8	2/8	5/8	3/5	2/5	4/4	4/4	0/4	3/4	3/3	0/3	0/4	NS	NS
<i>DEN.P</i>	4/8	4/4	0/4	4/8	4/4	0/4	0/4	NS	NS	0/4	NS	NS	1/4	1/1	0/1
<i>DP₁₀₋</i>	6/6	0/6	6/6	6/6	0/6	6/6	0/2	NS	NS	1/2	0/1	1/1	1/2	0/1	1/1
<i>DP₁₀₋₅₀</i>	6/6	0/6	6/6	6/6	0/6	6/6	0/2	NS	NS	1/2	0/1	1/1	2/2	0/2	2/2
<i>DP₅₀₋₁₅₀</i>	4/6	0/4	4/4	6/6	0/6	6/6	1/2	1/1	0/1	1/2	0/1	1/1	2/2	0/2	2/2
<i>DP₁₅₀₊</i>	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC	EXC
<i>DVEI</i>	8/8	8/8	0/8	8/8	8/8	0/8	0/4	NS	NS	0/4	NS	NS	0/4	NS	NS
<i>IND</i>	4/8	4/4	0/4	2/8	2/2	0/2	3/4	3/3	0/3	2/4	2/2	0/2	0/4	NS	NS
<i>TEMP</i>	4/8	4/4	0/4	6/8	6/6	0/6	4/4	4/4	0/4	4/4	4/4	0/4	2/4	2/2	0/2
<i>PREC</i>	7/8	2/8	5/8	4/8	4/4	0/4	4/4	1/4	3/4	2/4	2/2	0/2	4/4	4/4	0/4
<i>GPS_{pc}</i>	2/8	2/2	0/2	2/8	2/2	0/2	2/4	2/2	0/2	2/4	2/2	0/2	2/4	0/2	2/2
<i>UBS</i>	8/8	0/8	8/8	8/8	0/8	8/8	2/4	0/2	2/2	2/4	0/2	2/2	0/4	NS	NS
<i>PRS</i>	2/8	0/2	2/2	2/8	0/2	2/2	0/4	NS	NS	0/4	NS	NS	1/4	1/1	0/1
<i>HOSP</i>	3/8	0/3	3/3	4/8	0/4	4/4	0/4	NS	NS	0/4	NS	NS	0/4	NS	NS
<i>LTO</i>	4/8	1/4	3/4	4/8	1/4	3/4	2/4	2/2	0/2	1/4	0/1	1/1	1/4	0/1	1/1
<i>RESP</i>	4/8	4/4	0/4	4/8	4/4	0/4	2/4	2/2	0/2	2/4	2/2	0/2	0/4	NS	NS
<i>MED.C</i>	2/8	2/2	0/2	6/8	6/6	0/6	2/4	2/2	0/2	0/4	NS	NS	0/4	NS	NS
<i>MED.P</i>	4/8	4/4	0/4	4/8	4/4	0/4	2/4	2/2	0/2	0/4	NS	NS	0/4	NS	NS
<i>ENF.G</i>	2/8	2/2	0/2	3/8	3/3	0/3	0/4	NS	NS	2/4	2/2	0/2	1/4	1/1	0/1
<i>ENF.TI</i>	2/8	2/2	0/2	2/8	2/2	0/2	0/4	NS	NS	0/4	NS	NS	1/4	0/1	1/1
<i>P.SAU</i>	0/8	NS	NS	0/8	NS	NS	2/4	2/2	0/2	0/4	NS	NS	0/4	NS	NS
<i>D.COR</i>	2/8	2/2	0/2	2/8	2/2	0/2	4/4	4/4	0/4	4/4	4/4	0/4	0/4	NS	NS

Notas: a) Teste Sig.: revela em quantas estimações a variável foi significativa; b) Sinal: dentre os coeficientes significativos, mostra quantos obtiveram sinal negativo/positivo; c) NS = não significativo e EXC = excluída (referência); d) células *hachuradas* indicam o sinal predominante.

Fonte: Elaboração própria com base nos resultados das Tabelas 2 e 3.

5. CONSIDERAÇÕES FINAIS

Esta pesquisa teve por objetivo verificar quais características municipais poderiam afetar o número de casos e óbitos e as taxas de incidência, mortalidade e letalidade associadas à COVID-19. De modo geral, a literatura sugere que a poluição, alguns indicadores de saúde (e.g.: infraestrutura, equipamentos e capital humano) e fatores socioeconômicos, demográficos e climáticos seriam os principais responsáveis pelos surtos da doença em regiões específicas. Todavia, como o tema é recente, ainda existem poucos estudos sobre o mesmo, principalmente no Brasil, e, muitas vezes, o efeito da variável analisada é controverso.

Logo, visando identificar os efeitos destas características locais, usou-se os estimadores de Mínimos Quadrados Ordinários, Poisson e Binominal Negativo, com dados *cross-section*, referentes aos municípios de Minas Gerais e considerando os casos e óbitos de COVID-19 acumulados até 21 de abril/2021. Como não há uma especificação

bem definida para explicar esta pandemia, as variáveis, sugeridas pela literatura, foram avaliadas não apenas pelos estimadores supracitados, mas também por meio do teste de valores extremos, de Levine e Renelt (1992), denominado *Extreme Bounds Analysis*.

Os resultados sugerem que cidades pequenas, com ampla oferta de unidades básicas de saúde (UBS) e populações jovens teriam menos problemas com casos e óbitos por COVID-19. Por outro lado, locais sujeitos à aglomeração, ou seja, tipicamente urbanos, desiguais, com maior atividade econômica e circulação de empregados teriam mais dificuldade em controlar a pandemia.

Embora a poluição veicular também tenha se revelado nociva aos casos e óbitos, deve-se considerar a possibilidade de que esta variável esteja captando alguma forma de concentração local. Afinal, cidades com mais veículos por Km² seriam, naturalmente, mais aglomeradas. Portanto, mais estudos são necessários a fim de garantir que o problema esteja associado à poluição, e não à concentração em si. Quanto à proporção de médicos por habitante, que se mostrou positivamente associada aos óbitos, acredita-se que tal característica seja típica de cidades maiores e, portanto, com maior concentração de indivíduos.⁴ Alternativamente, é possível que uma parte relevante dos óbitos locais esteja associado ao pessoal da “linha de frente” no combate ao corona-vírus. Assim, quanto maior a equipe de saúde, maior seria o número de óbitos.

Os resultados ainda sugerem que locais de clima quente seriam mais propensos a ter casos e óbitos por corona-vírus, enquanto cidades chuvosas estariam sujeitas a menos casos, porém mais óbitos. Assim como Auler *et al* (2020), acredita-se que os indivíduos tenham mais dificuldade em manter o distanciamento social em locais quentes, com reflexos nocivos sobre os casos e óbitos. O oposto vale para a chuva, que dificultaria as aglomerações, reduzindo os casos. Ainda assim, o efeito positivo da precipitação sobre os óbitos requer novos estudos.

Verificou-se que a incidência de COVID-19 é maior em cidades urbanas, quentes, com menos chuvas, que concentram renda e trabalhadores e possuem histórico mais severo de doenças correlatas. Portanto, a concentração de indivíduos, com mais comorbidades, em locais que, possivelmente, dificultariam o distanciamento, tenderia a inflacionar a incidência desta doença.

Conforme esperado, a mortalidade pelo corona-vírus revelou-se menor entre a população mais jovem e com maior nível educacional. Tal como Ehlert (2020), acredita-se que os indivíduos com mais educação teriam acesso à melhores hospitais, tratamentos médicos e possuiriam vantagens informacionais sobre a doença. Assim como na incidência, a mortalidade também tenderia a aumentar em cidades quentes, com maior nível de atividade econômica e histórico de doenças correlatas.

Os modelos associados à letalidade da COVID-19 obtiveram um baixo poder explicativo (em relação aos demais), indicando a necessidade de maiores pesquisas sobre a mesma. Ainda assim, notou-se que a letalidade seria menor entre os jovens e em cidades de pequeno a médio porte (até 150 mil habitantes). Porém, igualmente ao número de óbitos, esta taxa também poderia aumentar em locais chuvosos.

Ao identificar quais características municipais prejudicariam o controle desta pandemia, acredita-se que os resultados desta pesquisa possam auxiliar a adoção de políticas específicas e regionalizadas no combate à COVID-19, inclusive quanto ao rigor das mesmas. Todavia, deve-se ressaltar que o uso de dados secundários, cujo foco é o município (e não o paciente) constituem uma limitação deste trabalho.

REFERÊNCIAS

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

⁴ Dentre as 20 cidades com maior concentração de médicos, encontram-se: Belo Horizonte, Montes Claros e Juiz de Fora que, sozinhas, representam quase 16,5% da população total do Estado de MG.

- 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 SCHAİK, A. B. T. M. Trust and economic growth: a robustness analysis. *Oxford Economic Papers*, Vol.56, p.118–134. 2004.
- 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>
- FIRME, V.A.C; SIMÃO FILHO, J. Análise do crescimento econômico dos municípios de minas gerais via modelo MRW (1992) com capital humano, condições de saúde e fatores espaciais, 1991-2000. *Economia Aplicada*, v. 18, n. 4, p. 679-716, 2014.
- 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*, 4ª ed. 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>.