

Fatores associados aos óbitos por Codiv-19 no Nordeste brasileiro: uma abordagem multinível

Factors associated with Codiv-19 deaths in the Brazilian Northeast: a multi-level approach

Adinésia Lima Leite¹ⁱ, Orcid: <https://orcid.org/0000-0002-0642-8353>; **Thiago Henrique Carneiro Rios Lopes²ⁱⁱ**, Orcid: <https://orcid.org/0000-0003-1550-1484>; **Fernanda Esperidião³ⁱⁱⁱ**, Orcid: <https://orcid.org/0000-0002-8580-2090>

1. Universidade Federal de Sergipe-UFS - São Cristovão - SE – Brasil. E-mail: adinesia.leite@dcomp.ufs.br
2. Universidade Federal de Sergipe-UFS - São Cristovão - SE – Brasil. E-mail: thiagohenriquerios@gmail.com
3. Universidade Federal de Sergipe-UFS - São Cristovão - SE – Brasil. E-mail: nandaesper16@gmail.com

Resumo

Em 2020 o mundo foi surpreendido pela Pandemia de COVID-19, causada pelo vírus SARS-Cov-2, que desencadeou uma crise humanitária, econômica e social a nível global. Nesse sentido, este trabalho teve como objetivo analisar os fatores associados aos óbitos por COVID-19 nos municípios do nordeste brasileiro em dois períodos distintos da pandemia: julho de 2020 e abril de 2021, respectivamente. Para obtenção dos resultados, foram estimados modelos logísticos hierárquicos com variáveis a nível individual e municipal. Os resultados indicaram que a probabilidade de óbito é maior entre os indivíduos do sexo masculino, com comorbidades, idosos e com menos escolaridade. Ademais, aqueles que receberam a vacina antiviral ou contra a COVID-19 também tiveram menor probabilidade de óbito. Assim, para o caso dos municípios do Nordeste, as características individuais foram mais relevantes para a compreensão dos óbitos durante a pandemia do que as características do próprio município.

Palavras-chave: pandemia de covid-19; modelos hierárquicos; região Nordeste

Abstract

In 2020, the world was surprised by the COVID-19 Pandemic, caused by the SARS-Cov-2 virus, which triggered a global humanitarian, economic, and social crisis. In this sense, this work aimed to analyze the factors associated with COVID-19 deaths in the municipalities of northeastern Brazil in two distinct periods of the pandemic: July 2020 and April 2021, respectively. To obtain the results, hierarchical logistic models were estimated with variables at the individual and municipal levels. The results indicated that the probability of death is higher among male individuals, with comorbidities, the elderly, and with less education. Moreover, those who received the antiviral or COVID-19 vaccine also had a lower probability of death. Thus, for the case of northeastern municipalities, individual characteristics were more relevant for understanding deaths during the pandemic than the characteristics of the municipality itself.

Keywords: Covid-19 pandemic; hierarchical models; northeast region

Referência: Leite, A. L., Lopes, T. H. C. R., & Esperidião, F. (2025). Fatores associados aos óbitos por Codiv-19 no Nordeste brasileiro: uma abordagem multinível. *Gestão & Regionalidade*, v. 41, e20259086. <https://doi.org/10.13037/gr.vol41.e20259086>

1 Introdução

Ao longo da pandemia causada pelo vírus SARS-Cov-2, vários pesquisadores se debruçaram para entender as razões que mais contribuíram para as mortes provocadas pelo novo coronavírus. Fatores como idade, vacinação e presença de comorbidades se apresentavam como



os elementos mais relevantes para aumentar a chance de óbito. Contudo, este artigo sugere que as características do ambiente em que os indivíduos se encontram também podem ajudar a compreender esta questão (Santos & Teixeira, 2022).

A pandemia da COVID-19 tem afetado em maior proporção os grupos mais vulneráveis econômica e socialmente. Em função do processo de formação econômica do país, o Brasil é marcado por profundas diferenças econômicas, sociais e culturais (Cano & Guimarães Neto, 1986) que precisam ser consideradas neste estudo. Dessa forma, a análise aqui proposta restringir-se-á aos municípios da Região Nordeste. Esta região ainda possui frágeis indicadores socioeconômicos que poderiam potencializar a chance de óbito durante a pandemia.

Como exemplo de um indicador socioeconômico podemos citar a alimentação. Segundo IBGE (2019), nos estados do Nordeste, 46,1% dos domicílios estão abaixo da média nacional (69,8%) em relação à alimentação adequada. Além disto, sobre o Rendimento Médio Mensal Per Capita, a região nordeste apresenta os menores rendimentos do país e uma elevada concentração de renda. O Índice de Gini dos estados que compõem a Região Nordeste varia entre 0,5 e 0,6 em os estados, e isso demonstra um elevado grau de concentração de renda, pois quanto mais próximo de 1, maior a desigualdade.

Destaca-se, ainda, a investigação sobre o nível de capital humano dos indivíduos enquanto elemento capaz de reduzir as chances de mortes durante o período mais crítico.

O aumento no nível educacional contribui para a redução da desigualdade social entre classes e regiões do país (Cruz, Teixeira, & Braga, 2010). Segundo Balassiano et al. (2005), a maior facilidade de encontrar emprego vem sendo diretamente associada à questão da qualificação profissional, sendo representada por um conjunto de atributos que incluem aspectos relativos à educação formal, à capacidade de aprender permanentemente, de empreender, além de um conjunto de atitudes como iniciativa, autonomia e versatilidade. Esses atributos garantiriam aos trabalhadores a empregabilidade, isto é, a capacidade de permanecer no mercado de trabalho.

Mais especificamente, este trabalho investiga também se o maior nível de capital humano dos indivíduos dos municípios da Região Nordeste está associado a uma menor taxa de mortalidade provocada pela COVID-19. Espera-se que quanto maior o nível de capital humano dos indivíduos, menor será a taxa de letalidade causada pela COVID-19, pois pessoas com maior nível de escolaridade têm comportamentos mais saudáveis, como práticas de exercícios físicos, melhor alimentação, maior cuidado com a higiene e realização de exames preventivos. Ademais, indivíduos com melhor qualificação profissional teriam maiores chances de trabalhar em casa evitando, assim, maior exposição ao vírus. Além disso, os efeitos benéficos do capital humano são multidimensionais: macroeconômicos, individuais e sociais, que podem contribuir positivamente para uma menor taxa de mortalidade na região (Besarria et al., 2016; Campos & Miranda, 2021).

Os resultados indicaram que a probabilidade de óbito é maior entre os indivíduos do sexo masculino, com comorbidades, idosos e com menos escolaridade. Ademais, aqueles que receberam a vacina antiviral ou contra a COVID-19 também tiveram menor probabilidade de óbito.

Este trabalho está dividido em três seções, além desta introdução e das considerações finais. A segunda seção possui uma revisão da literatura empírica sobre os fatores determinantes da COVID-19. A seção seguinte apresenta a metodologia utilizada, bem como a fonte e tratamento dos dados. Por fim, a última seção estima os modelos econométricos e discorre sobre os principais resultados encontrados.



2. Revisão de Literatura Empírica

A pandemia de COVID-19 desencadeou uma série de eventos que evidenciaram como os fatores socioeconômicos estão associados com a evolução das doenças infecciosas ao longo da história. No contexto brasileiro, as desigualdades no acesso ao tratamento tornaram-se um fator crucial na determinação da taxa de letalidade da doença. Alguns estudos empíricos, que serão apresentados ao longo desta seção, revelam impactos significativos de diversas características no aumento do risco de óbito, incluindo faixas etárias mais avançadas, indivíduos de origem negra e parda, bem como aqueles com menor nível de escolaridade. O estudo realizado por Batista et al. (2020) lançou luz sobre essas disparidades, analisando a variação da taxa de letalidade no Brasil em relação a fatores socioeconômicos. Além disso, conforme será observado, municípios com baixo IDH demonstraram taxas de letalidade mais elevadas. Estes achados não apenas ecoam em um contexto global, como demonstrado por estudos em Detroit, Michigan (Laster Pirtle, 2020) e em países de todo o mundo (Chaudhry et al., 2020), mas também destacam a necessidade premente de ações efetivas para reduzir as desigualdades socioeconômicas e regionais na resposta à pandemia.

Os fatores socioeconômicos foram importantes para explicar o processo de evolução das pandemias ao longo da história. No caso brasileiro em particular, a taxa de letalidade foi influenciada pelas desigualdades no acesso ao tratamento (Batista et al., 2020). Neste sentido, Batista et al. (2020) se propuseram a analisar a variação da taxa de letalidade da doença no Brasil, levando em consideração os fatores socioeconômicos, tais como, idade, gênero, raça, IDH, escolaridade e cidade do caso registrado. Por meio de uma análise descritiva, foi constatado que os óbitos são influenciados pela idade - nas faixas etárias acima de 60 anos, mais de 50% dos casos resultaram em óbitos. No quesito raça/cor, a proporção de negros e pardos que morreram (54,78%) foi superior aos de brancos (37,93%). Quanto à escolaridade, as pessoas com nível de escolaridade superior apresentaram uma menor proporção de óbitos (22,5%), que aquelas sem escolaridade (71,3%), refletindo que quanto maior o nível de educação, menor a letalidade da doença. Além disso, a pesquisa evidenciou também que a percentagem de óbitos de pretos e pardos foi maior em relação aos brancos em todos os níveis de escolaridade e faixas etárias. Por fim, foi observado que nos municípios com baixo ou médio IDH, a chance de o paciente infectado vir a óbito foi praticamente o dobro em relação aos municípios com alto índice de desenvolvimento humano.

Estudo semelhante foi realizado na cidade de Detroit, Michigan, nos Estados Unidos. Na cidade, apenas 14% da população é negra, entretanto, as estatísticas confirmaram que dos óbitos diretos relacionados à COVID-19, 40% foram de negros, evidenciando as disparidades raciais e socioeconômicas, pois a maior parte da população pertencente a esse grupo são os mais vulneráveis em termos socioeconômicos. (Laster Pirtle, 2020).

Pires, Carvalho e Xavier (2020) utilizando os dados divulgados pela Pesquisa Nacional de Saúde (PNS) do IBGE realizada em 2013, realizaram uma estimativa da proporção de brasileiros que se enquadram no grupo de risco para a COVID-19. Foram classificadas como pertencentes ao grupo de risco as pessoas acima de 60 anos e com comorbidades. A pesquisa evidenciou que a incidência de comorbidades é maior nos brasileiros que só frequentaram o ensino fundamental em relação aos demais grupos. Dessa forma, a pesquisa deixa claro que a população de baixa renda é a mais vulnerável à crise epidemiológica e de saúde pública.

Nessa mesma linha de raciocínio, utilizando a mesma base de dados, Borges e Crespo (2020) tiveram como objetivo caracterizar os grupos de risco para a COVID-19 no Brasil e estimar o número de pessoas convivendo na mesma residência com indivíduos do grupo de risco. Para isso, o ferramental analítico usado na estimação foi o modelo de regressão logística.



O estudo levou em consideração a idade, sexo, grande região, cor ou raça, nível de escolaridade e condição em relação à força de trabalho dos moradores entrevistados pela pesquisa. Os resultados destacaram que a idade é o principal fator de risco para comorbidades associadas à COVID-19, mas foi possível observar que há também maior risco para pessoas em categorias mais vulneráveis, como os menos escolarizados e pretos e pardos. Ademais, a estimativa revelou que 68,7% dos brasileiros conviviam com pelo menos uma pessoa no grupo de risco.

Souza et al. (2021) analisaram os fatores de risco de mortalidade para pacientes hospitalizados com COVID-19 no Brasil, durante o período de 26 de fevereiro a 10 de agosto de 2020. O estudo em questão mostrou que a taxa de letalidade foi maior em idosos de ambos os sexos, porém a taxa de letalidade foi um pouco maior no gênero masculino. Além disso, foi verificada uma alta taxa de letalidade na região Norte / Nordeste, nas maiores faixas etárias, nas populações não brancas e nos níveis de escolaridade mais baixos. De acordo com os autores, a maior letalidade na região Norte / Nordeste pode ser decorrente das condições socioeconômicas e da disponibilidade de leitos em UTI. Por outro lado, também pode ser devido à falta de conhecimento adequado sobre as características da nova doença, cuja disseminação era maior nesta região no início da pandemia.

Pinheiro et al. (2020) objetivaram identificar a relação entre as características regionais e os fatores epidemiológicos e sociais na mortalidade por Covid-19 no Brasil. Os resultados apontaram diferenças entre as regiões brasileiras, expondo as desigualdades no acesso aos serviços de saúde, além de afirmar que o perfil epidemiológico e social contribuiu para aumentar a letalidade nas regiões Norte e Nordeste. Portanto, a pesquisa reforça a necessidade de ações efetivas para reduzir as desigualdades regionais.

A pandemia de COVID-19 acentuou também as desigualdades no acesso aos sistemas de saúde, ampliando as diferenças raciais e piorando o resultado de saúde nesses grupos populacionais (PERES et al., 2021). Neste sentido, Peres et al., (2021) objetivaram analisar a associação entre as características sociodemográficas e a mortalidade hospitalar causada pela COVID-19 no Brasil.

Para realização da análise, foi usado o modelo de regressão logística. A população estudada incluiu os pacientes adultos hospitalizados com COVID-19 com desfecho definido (228.196), no período de 16 de fevereiro a 08 de agosto de 2020. A pesquisa revelou que a mortalidade total foi de 37%, sendo que entre pacientes negros / pardos a mortalidade foi de 42% ante 37% para pacientes brancos.

Além disso, os negros / pardos foram admitidos com menos frequência na unidade de terapia intensiva (32%) em relação aos brancos (36%), e usaram ventilação mecânica mais invasiva (21%), comparados aos pacientes declarados brancos (19%). Diante do resultado, fica evidente a necessidade de implementar estratégias ativas para reduzir as discrepâncias causadas pelos determinantes mais amplos da saúde, levando a uma mudança sustentável no sistema de saúde (Peres et al., 2021).

Chaudhry et al. (2020) realizaram uma análise exploratória com os 50 principais países em termos de casos relatados, objetivando avaliar os impactos das intervenções na saúde da população, fatores socioeconômicos de cada país e número de óbitos. Os resultados mostraram que o maior número de casos e mortalidade geral foram associados à comorbidades, como obesidade e idade avançada da população. Em oposição, uma menor dispersão da renda dentro do país reduziu a mortalidade geral e os casos críticos. Além disso, a política governamental de bloqueio total foi positivamente relacionada às taxas de recuperação, evidenciando que o bloqueio total e o fechamento antecipado das fronteiras podem diminuir o pico de transmissão e, assim, evitar o excesso de capacidade do sistema de saúde, o que facilitaria o aumento das



taxas de recuperação. Entretanto, os países com maior PIB per capita apresentaram aumento dos casos críticos e mortes por milhão de habitantes.

De acordo com os autores, isso pode estar associado a maior testagem da população, maior transparência com as divulgações dos dados e melhores sistemas de vigilância. Todavia, os pesquisadores ressaltam que esse resultado pode estar associado, também, a viagens aéreas e feriados internacionais em países mais ricos.

Silva (2021) objetivando analisar a prevalência de infecção pelo Novo Coronavírus no Pará, notou que o vírus não atinge a população de forma democrática. A pesquisa demonstrou que o avanço da Covid-19 no Estado ocorre entre os mais empobrecidos (classes C, D e E) e entre aqueles com baixo nível de escolaridade (Fundamental ao Médio). No quesito cor/raça a pesquisa identificou não haver tanta diferença entre as proporções de pessoas com anticorpos. Assim, conclui-se que no Estado, a classe e o nível de escolaridade delinearam uma distribuição muito desigual de riscos para o contágio. Além disso, a pesquisa assevera serem esses grupos os mesmos que compõem a força de trabalho que está mais exposta a contrair o vírus por meio de seus empregos, por vezes, informais, cujas atividades são realizadas fora de casa, intensificando, deste modo, o contato interpessoal.

Barbosa, Costa e Hecksher (2020) identificaram quais trabalhadores sofreram maior impacto em termos de perda de ocupação no Brasil durante a crise econômica causada pela pandemia do novo coronavírus. O estudo revelou que os grupos com maiores probabilidades de perder o emprego são os jovens e as mulheres, cerca de 20%. Destaca-se, ainda, que a proporção de pretos e pardos que perdem o emprego encontra-se sempre acima da média e chega a alcançar 18% no início da crise (uma elevação de 5 p.p. vis-à-vis 4 p.p. entre os brancos). Com relação ao nível de escolaridade, possuir ensino médio incompleto ou menos representou uma chance de 15% de migrar para o desemprego ou para fora da força de trabalho. No que diz respeito aos postos de trabalho, destacam-se os trabalhadores com jornada parcial, informais e com menores salários entre os que tiveram perdas significativas.

Em síntese, os estudos apresentados ao longo desta seção ressaltam o papel dos fatores socioeconômicos na evolução das pandemias, com destaque para a pandemia de COVID-19 no Brasil. As desigualdades no acesso ao tratamento emergem como um fator crítico que influencia diretamente as taxas de letalidade da doença. Essas disparidades se manifestam de diversas maneiras, incluindo diferenças significativas nas taxas de óbito entre faixas etárias, grupos raciais e de escolaridade, bem como em regiões com menor Índice de Desenvolvimento Humano (IDH). A análise conjunta dessas pesquisas reforça necessidade do desenvolvimento de estratégias e políticas públicas voltadas para a redução das desigualdades sociais e regionais, com o propósito de promover uma abordagem mais equitativa e eficaz no enfrentamento das crises de saúde pública.

2.1 Interiorização da Pandemia Covid-19 no Brasil

Conforme exposto anteriormente, a pandemia da COVID-19 desencadeou uma série de desafios de saúde pública e impactos sociais significativos. No entanto, além das grandes metrópoles e áreas urbanas densamente povoadas que inicialmente receberam a maior atenção, a pandemia também teve uma influência profunda na interiorização. As regiões menos densamente povoadas, muitas vezes consideradas distantes dos epicentros urbanos, não escaparam das consequências da disseminação do vírus. Nesta seção, exploraremos a dinâmica da interiorização da COVID-19, examinando como as áreas mais distantes dos grandes centros



urbanos também enfrentaram desafios significativos relacionados à saúde, infraestrutura e acesso aos cuidados médicos.

Silva et al. (2020) conduziram uma análise exploratória do aumento na mortalidade atribuída à pandemia da COVID-19 no Brasil, abrangendo o período de março a maio de 2020. Esta investigação abarcou tanto as capitais quanto os municípios do país, com a utilização de dados provenientes dos registros de óbitos dos Cartórios de Registro Civil. O estudo comparou o número de óbitos efetivamente registrados com o número de óbitos que se esperava ocorrer em 2019, desagregando as informações por gênero e localidade. Os autores observaram um aumento significativo nas razões de mortalidade padronizadas nos municípios do interior das regiões Norte, Nordeste e Sudeste, que ocorreu principalmente em maio. O perfil de mortalidade se alterou inicialmente nas capitais dessas regiões, mas com o deslocamento da epidemia, passou a ocorrer um excesso de mortes nos municípios fora das capitais.

Alguns trabalhos se concentraram em avaliar a interiorização da pandemia em alguns estados do Nordeste. Pedrosa e Albuquerque (2020), por exemplo, analisaram a distribuição dos casos de COVID-19 e dos leitos de UTI específicos para a doença no estado do Ceará, através de recursos de Sistemas de Informação Geográfica. Os autores realizam uma análise exploratória da distribuição espacial da COVID-19, a partir de casos registrados entre 15 de março de 2020 e 18 de abril de 2020. O Índice de Moran foi calculado para verificar a dependência espacial da distribuição do coeficiente de detecção bruto, taxa bayesiana global e local. Segundo Pedrosa e Albuquerque (2020), a interiorização da pandemia se refere à disseminação da doença para áreas em que anteriormente não haviam sido registrados casos. No caso do Ceará, a interiorização da COVID-19 foi observada através da identificação de clusters com padrão Alto-Alto da doença em outras regiões do estado, além da capital e região metropolitana, sugerindo uma disseminação mais ampla da doença no território cearense.

É possível inferir, de um modo geral, que essa disseminação pode ter sido causada por diversos fatores, como viagens de pessoas infectadas, aglomerados em eventos sociais, maior circulação de pessoas nas estradas, entre outros. Essas causas são comuns a muitas outras regiões do mundo onde a pandemia se espalhou rapidamente para áreas antes livres da doença. A compreensão da interiorização das pandemias é importante para entender a propagação da doença, bem como para tomadas de decisão em relação à alocação de recursos específicos, como leitos de UTI para os pacientes, a fim de melhor atender às necessidades das regiões afetadas.

Este é um problema que desafia a resposta ao controle das pandemias nas regiões mais remotas do país, dada a disseminação acelerada em municípios de pequeno porte no Brasil. Trabalhos como o de Gomes et al (2021), destacam que a distribuição da COVID-19 ocorreu de forma heterogênea nas regiões de saúde, com os primeiros casos sendo identificados nas capitais brasileiras e, posteriormente, novos casos detectados em regiões mais afastadas. Ao descreverem o perfil epidemiológico e a distribuição espacial dos óbitos e casos confirmados na macrorregião de saúde Oeste da Bahia, os autores acreditam que a interiorização da COVID-19 pode afetar o sistema de saúde da macrorregião, dado que muitos municípios não têm sequer hospital. Sendo assim, a interiorização das pandemias é um fenômeno preocupante, uma vez que pode impactar regiões onde a disponibilidade e qualidade dos serviços de saúde podem ser limitadas.



Quinino et al (2021), realizaram uma análise espacial e temporal da incidência e interiorização da Covid-19 no estado de Pernambuco, Brasil, entre março e junho de 2020, observando os fatores socioeconômicos relacionados. Segundo os autores, a pandemia de Covid-19 teve um efeito desproporcional nas regiões metropolitana e interior (rural) de Pernambuco, mostrando concentração de casos nas áreas urbanas. Os primeiros casos foram registrados em municípios da região metropolitana, com sua disseminação para o interior ocorrendo posteriormente. Eles identificaram agrupamentos espaciais significantes de municípios com altas e baixas incidências e os de transição, sendo que os municípios com os maiores coeficientes de incidência com vizinhos com altas taxas concentraram-se na Região Metropolitana do Recife (RMR), enquanto aqueles com baixos coeficientes de incidência com vizinhos baixos encontram-se nas mesorregiões do Sertão e São Francisco. As principais áreas de risco para Covid-19 em Pernambuco situam-se na Região Metropolitana do Recife, enquanto os municípios mais afetados situam-se no interior do estado, como Caruaru e Palmares, que apresentaram os maiores coeficientes de incidência.

O estudo supracitado sugere alguns motivos da interiorização da pandemia, tais como: i) a introdução da doença em cidades cujo crescimento populacional não foi acompanhado de desenvolvimento urbano; ii) a migração pendular das pessoas para cidades de melhores condições de vida e onde se concentram a infraestrutura, os serviços de saúde e a educação; iii) as diferenças socioeconômicas entre as populações urbanas e rurais e a falta de acesso à informação e a serviços de saúde de qualidade; e iv) as iniquidades sociais, onde o impacto da pandemia recai de forma mais problemática e a adesão às recomendações fica comprometida. Nesta direção, Quinino et al (2021) apontam algumas consequências da interiorização da Covid-19 como a capacidade limitada dos serviços de saúde para fornecer cuidados intensivos no interior. Ademais, como as áreas do interior costumam abrigar populações historicamente carentes, há maiores dificuldades de acesso a serviços de saúde adequados. Por conseguinte, o aumento dos casos de Covid-19 no interior pode levar a pandemia a progredir silenciosamente, sem detecção e, eventualmente, evoluir para situações graves e colapso do sistema de saúde.

3. Dados e Método

Para obtenção do que se propõe neste trabalho, será adotado um modelo hierárquico, também conhecido como multinível, mais precisamente um modelo de regressão logística hierárquico. Tal modelo é adequado porque leva em consideração a estrutura do agrupamento dos dados. Isto é, além da importância das características individuais, consideram-se as especificidades do ambiente em que o indivíduo se encontra, pois tais especificidades podem afetar a probabilidade do indivíduo vir ou não a óbito em decorrência da infecção causada pelo vírus SARS-CoV-2 (SOARES; MENDONÇA, 2003; LOPES, 2015).

Nos modelos hierárquicos os dados comportamentais e sociais geralmente possuem uma estrutura agrupada. Assim, cada um dos níveis na estrutura é formalmente representado por um submodelo próprio. Estes submodelos exprimem relações entre variáveis dentro de um determinado nível, e explicitam como influenciam as relações que ocorrem em outro (Raudenbush & Bryk, 2002).

Na especificação do modelo multinível, o intercepto e o coeficiente de inclinação são considerados parâmetros aleatórios, dependentes da influência do nível hierárquico mais alto (Soares & Mendonça, 2003). Considera-se que os dados estão hierarquicamente estruturados



em dois níveis: no primeiro estão os indivíduos que, por sua vez, estão aninhados no segundo nível, composto pelos municípios do nordeste brasileiro.

Conforme destacado por Lopes (2015), o modelo do componente da variância implica em efeitos aleatórios, de modo que a variação no intercepto é capturada pela variância nos resíduos de segundo nível. A estimação deste modelo permitirá avaliar se a abordagem hierárquica será realmente necessária. Sendo constatada a necessidade de tal abordagem, o próximo passo é incluir variáveis de primeiro nível com intercepto aleatório. Especificamente,

$$y_{ij} = \beta_0 j + \beta_1 X_{ij} + e_{ij} \quad (1)$$

Sendo que

$$\beta_0 j = \beta_0 + u_{0j} \quad (2)$$

Note, pois, que a linha de cada unidade do segundo nível é dada por:

$$y_j = (\beta_0 + u_{0j}) + \beta_1 X_{ij} \quad (3)$$

Em que $(\beta_0 + u_{0j})$ é o intercepto específico das unidades do segundo nível. Deve-se observar que o coeficiente angular é, por ora, comum a todas as unidades do segundo nível. β_0 e β_1 são coeficientes fixos da regressão; u_{0j} e e_{ij} são efeitos aleatórios ou resíduos multiníveis. Os parâmetros aleatórios apresentados anteriormente, $\sigma_u^2 + \sigma_e^2$, devem ser estimados juntamente com os coeficientes fixos da regressão (Lopes, 2015).

O modelo hierárquico de fato a ser estimado é um *logit*, pois a variável dependente é binária. Assim, o modelo de intercepto aleatório será algo como:

$$\log \left(\frac{\pi_{ij}}{1-\pi_{ij}} \right) = \beta_0 + \beta_1 x_{ij} + u_j \quad (4)$$

Em que $u_j \sim N(0, \sigma_u^2)$.

Considere que temos uma variável explanatória de primeiro nível, x_{1ij} , e outra variável de segundo nível, x_{2j} . O modelo *logit* de intercepto aleatório representado pela equação 4 pode ser estendido para incluir ambos preditores:

$$\log \left(\frac{\pi_{ij}}{1-\pi_{ij}} \right) = \beta_0 + \beta_1 x_{ij} + \beta_2 x_{2j} + u_j \quad (5)$$

As investigações que consideram em seus modelos a estrutura de agrupamento dos dados apresentam algumas vantagens, dentre elas: se embasam em modelos mais flexíveis e estruturados que fazem melhor uso da informação presente na amostra; o uso da informação do agrupamento dos dados proporciona formular e testar hipóteses relativas a efeitos entre os níveis (Soares & Mendonça, 2003).

Assim, a equação (5) pode ser descrita:

$$\begin{aligned} Obtos_Cov_{it} = & A_i + B_1 Nivel_escol_{it} + B_2 raça_{it} + B_3 idade_{it} + B_4 sexo_{it} + \\ & B_5 fator_de_risco_{it} + B_6 vacina_COV_{it} + B_7 IDHM_{it} + B_8 Pop_agua_encanada_{it} + \\ & B_9 Pop_coleta_lixo_{it} + B_{10} PIBpc_{it} + \varepsilon_{it} \end{aligned} \quad (6)$$

A descrição de cada variável está apresentada no Quadro 1, seção a seguir.

3.1 Fonte e tratamento dos dados



Três bases de dados foram utilizadas neste estudo. A primeira decorre de informações diárias obtidas pelo do Banco de Dados de Síndrome Respiratória Aguda Grave - incluindo dados da COVID-19 (SRAG 2020), alimentada pelas notificações realizadas pelas unidades de saúde públicas e privadas e disponibilizadas pelo Ministério da Saúde (OpenDataSUS), atualizados em 24/11/2021 e 29/11/2021, referentes aos períodos de 2020 e 2021, respectivamente. Ressalta-se que, apesar do referido banco de dados disponibilizar informações de Síndrome Respiratória Aguda e Grave, para esta pesquisa foi selecionado apenas os dados referentes à COVID-19.

A segunda fonte foi o Atlas de Desenvolvimento Humano, em que foi possível obter informações do Índice de Desenvolvimento Humano Municipal (DHM), assim como os dados referentes ao saneamento básico e coleta de lixo, que serão utilizadas como variáveis de controle no modelo econométrico. A pesquisa focou nos municípios da região Nordeste, compreendendo o total de 1793.

Por fim, variáveis relacionadas ao PIB per capita foram coletadas na *home page* do Instituto Brasileiro de Geografia e Estatística (IBGE). A descrição das variáveis utilizadas é apresentada a seguir:

EVOLUÇÃO = refere-se ao desfecho do caso, isto é, se o paciente veio a óbito ou não em decorrência das complicações causadas pela COVID-19. Os dados foram obtidos no site OpenDataSUS;

FAT_RISCO = variável que indica se o paciente apresenta alguma comorbidade. Os fatores de risco estão associados a maiores ocorrências de óbitos em virtude da COVID-19, conforme resultados apresentados na parte empírica deste trabalho. Os dados foram obtidos no site OpenDataSUS;

IDADE = indica a idade do paciente. Assim como os fatores de risco, a idade está diretamente relacionada à maior prevalência de óbitos em consequência da COVID-19. Os dados também foram extraídos do site OpenDataSUS;

RACA = representa a cor/raça declarada pelo paciente. Objetivou-se investigar se a raça/cor contribuiu para uma maior ou menor taxa de óbitos pela Covid-19 ;

ESCOL = representa o nível de escolaridade informada pelo paciente. Proxy para o capital humano, o objetivo é verificar a relação inversamente proporcional entre capital humano e óbitos por Covid-19. Espera-se que quanto maior o nível desse capital, menor serão as taxas de óbitos em virtude da Covid-19. Os dados também foram obtidos do site OpenDataSUS;

SEXO = indica o sexo do paciente, masculino ou feminino. O propósito consiste em verificar a relação da variável com a maior probabilidade de óbitos causada pela Covid-19.

VACINA = indica se o paciente tomou a vacina contra a gripe na última campanha. Neste sentido, o intuito é verificar se a imunização pelo antiviral contribui para reduzir a probabilidade de óbitos causados pelo SARS-CoV-2;

VACINA_COV = indica se o paciente foi imunizado com a vacina contra a Covid-19. Supõe-se que o imunizante tenha contribuído para uma menor taxa de óbitos causada pela doença;

IDHM = indicador sucinto do progresso de três dimensões básicas do desenvolvimento humano: renda, educação e saúde. A inclusão dessa variável está relacionada à hipótese de que municípios com IDH melhor corroboram para uma menor taxa de óbitos pela pandemia de Covid-19. Os dados foram obtidos no Atlas de Desenvolvimento Humano no Brasil (2010);

InPIBpc = logaritmo do PIB per capita a preços correntes, ano base 2018. Os dados foram obtidos no site do IBGE;



POP_AGUA_ENC = percentual da população em domicílios com água encanada. A finalidade consiste em verificar se melhores condições de saneamento básico contribui para uma menor taxa de óbitos pela Covid-19. Os dados foram extraídos do Atlas do Desenvolvimento Humano no Brasil (2010);

POP_COL_LIXO = percentual de pessoas em domicílios urbanos com coleta de lixo. A finalidade consiste também em verificar se melhores condições de saneamento básico contribui para uma menor taxa de óbitos pela Covid-19. Os dados foram extraídos do Atlas do Desenvolvimento Humano no Brasil (2010);

O Quadro 1 apresenta de forma resumida as variáveis do modelo, alguns trabalhos que empregaram as mesmas variáveis em suas análises estatísticas, bem como seus sinais esperados em relação a probabilidade de óbito causada pela COVID-19.

Quadro 1 – Variáveis e autores que usaram as mesmas variáveis em seus estudos

Variável	Fonte	Trabalhos que analisaram variável questão	Sinal Esperado em relação a probabilidade de óbito por COVID-19
Nível de Escolaridade	OpenDataSUS (2021)	Batista et al. (2020); Pires, Carvalho e Xavier (2020); Borges e Crespo (2020); Pinheiro et al. (2020)	(-) Quanto maior a escolaridade, menor a probabilidade de óbito causado pela COVID-19
Raça/cor	OpenDataSUS (2021)	Batista et al. (2020); Borges e Crespo (2020); Pinheiro et al. (2020); Peres et al. (2021)	(+) Negros de indígenas devem ter maior probabilidade de morte pela COVID-19 em relação aos brancos
Idade	OpenDataSUS (2021)	Batista et al. (2020); Pires, Carvalho e Xavier (2020); Borges e Crespo (2020); Pinheiro et al. (2020)	(+) Quanto maior a idade, maior a probabilidade de óbito pela COVID-19
Sexo (homem)	OpenDataSUS (2021)	Borges e Crespo (2020); Pinheiro et al. (2020)	(+) Homens devem ter maior probabilidade de óbito pela COVID-19 em relação às mulheres
Fator de risco (comorbidade)	OpenDataSUS (2021)	Pires, Carvalho e Xavier (2020); Borges e Crespo (2020); Pinheiro et al. (2020); Chaudhry et al. (2020).	(+) Indivíduos com alguma comorbidade devem apresentar maior probabilidade de óbito por COVID-19 em relação àquelas sem comorbidade
Vacina_COV	OpenDataSUS (2021)	Rossman et al. (2021)	(-) Indivíduos vacinados devem ter menor probabilidade de óbito por COVID-19 em relação aos não vacinados



IDHM	Atlas de Desenvolvimento Humano no Brasil (2010)	Batista et al. (2020)	(-) Indivíduos que residem em cidades com maior IDHM devem ter menor probabilidade de óbito por COVID-19
PIB per capita	IBGE (2018)	Chaudhry et al. (2020)	(-) Indivíduos que residem em cidades com maior PIB per capita devem ter menor probabilidade de óbito por COVID-19
População com água encanada	Atlas do Desenvolvimento Humano no Brasil (2010);	-	(-) Indivíduos que residem em cidades com maior acesso à água encanada devem ter menor probabilidade de óbito por COVID-19
População com coleta de lixo	Atlas do Desenvolvimento Humano no Brasil (2010);	-	(-) Indivíduos que residem em cidades com maior acesso à coleta de lixo devem ter menor probabilidade de óbito por COVID-19

Fonte: Elaboração própria a partir da literatura apresentada.

3.2 Dados faltantes e imputação

O banco de dados deste trabalho possui valores faltantes, os quais foram imputados através do processo de imputação múltipla. Conforme destacado por Rubin (1987) a imputação múltipla é a técnica que substitui cada valor ausente por dois ou mais valores aceitáveis, representando uma distribuição de possibilidades. Este é um método que consiste em três estágios: i) são criados m conjuntos de dados completos e cada valor ausente é preenchido m vezes por meio de um modelo de imputação apropriado, dado os valores observados; ii) os m conjuntos de dados completos imputado são analisados usando procedimentos padrão de dados completos, como se os dados imputados fossem os dados reais obtidos dos não respondentes; e iii) os m resultados obtidos dos conjuntos de dados completos imputados são combinados de maneira simples e apropriada para obter a chamada inferência de imputação repetida (Rubin, 1987; Zhang, 2003; Nunes, 2007).

Dentre os métodos de imputação múltipla, foi realizado o método de Imputação Multivariada por Equações Encadeadas (MICE - Multivariate Imputation by Chained Equations). Segundo Van Buuren (2007), este método assume que, para cada variável com dados faltantes, o usuário especifica uma distribuição condicional para os valores ausentes dados os valores observados. Por exemplo, para variáveis binárias incompletas pode-se usar a regressão logística, para dados categóricos a regressão politômica e a regressão linear para dados contínuos, conforme foi feito nesta pesquisa e especificado adiante. Partindo do pressuposto de que existe uma distribuição multivariada da qual essas distribuições condicionais podem ser derivadas, o MICE constrói um amostrador de Gibbs a partir das condicionais especificadas. Este amostrador é usado para gerar múltiplas imputações (Van Buuren, 2007).

Neste sentido, devido às particularidades das variáveis analisadas nesta pesquisa, foram ajustados modelos de regressões para cada variável em particular, para os dois períodos



analisados, julho/2020 e abril/2021, que correspondem aos picos de contaminação em cada ano. As variáveis imputadas foram: evolução, raça, nível de escolaridade e idade para ambos os períodos; vacina e vacina_cov para julho/2020 e abril/2021, respectivamente.

Assim, para imputar os dados faltantes da variável IDADE, foi estimado um modelo de regressão linear, por se tratar de uma variável contínua, onde a referida variável foi regredida contra as seguintes variáveis: idade, evolução, raça, nível de escolaridade, vacina, logaritmo do PIP per capita, fator de risco, sexo e população com abastecimento de água.

No caso da variável EVOLUÇÃO, foi estimado um modelo de regressão logístico, porque a variável em questão é binária, referindo-se ao desfecho do caso (óbito/não óbito). Para imputar os valores ausentes da variável RAÇA, foi estimado um modelo de regressão logístico multinomial, pois trata-se de uma variável categórica, isto é, uma variável em que não há uma ordenação lógica entre as classificações da categoria.

Por sua vez, para imputação dos valores não observados da variável escolaridade (ESCOL) estimou-se uma regressão logística ordinal, cujos dados são apresentados em categorias com ordenação (Abreu; Siqueira; Caiaffa, 2009). A imputação dos dados ausentes das variáveis VACINA e VACINA_COV foram feitas por meio de regressões logísticas, por se tratarem de variáveis binárias. Imputados os dados ausentes, o passo seguinte foi estimar os modelos econométricos cujos resultados serão apresentados e discutidos na seção seguinte.

4. Resultados e Discussão

Ao considerar os dados referentes aos picos de contaminação, Julho/2020 e Abril/2021, observa-se que a média da idade dos indivíduos foi de aproximadamente 60 e 57 anos, respectivamente. Cabe destacar que 36,8% e 35,4% dos casos, neste período, tiveram como desfecho o óbito. O IDH dos municípios da Região Nordeste, analisados nesta pesquisa, apresentou média de aproximadamente 0,68 para ambos os períodos considerados. Este indicador merece destaque porque pode estar relacionado com o maior número de óbitos causado pela COVID-19, conforme constatado por Alberti et al. (2021).

Ademais, em julho/2020, 64,89% dos indivíduos possuíam algum fator de risco. Já no segundo período de análise, abril de 2021, 59,17% das pessoas apresentavam uma ou mais doenças. Ressalta-se que os fatores de risco estão diretamente relacionados ao maior número de óbitos em decorrência das complicações causadas pela Covid-19, conforme apresentado anteriormente.

A Tabela a seguir mostra os resultados dos procedimentos econôméticos encontrados, tendo a EVOLUÇÃO como variável dependente. Isto é, trata-se de uma variável binária em que 1 indica que o indivíduo veio a óbito e 0 em caso contrário. É importante destacar que existem quatro modelos na Tabela 1. Os dois primeiros consideram os dados de todo ano de 2020 - *Dados completos 2020* - e todo o ano de 2021 - *Dados completos 2021*, ambos ignorando os dados faltantes. Os dois últimos modelos - *Imputação 2020* e *Imputação 2021* - contém dados apenas durante o período de pico da pandemia, julho de 2020 e abril de 2021, respectivamente, e os dados faltantes foram imputados conforme exposto na seção anterior. O objetivo é verificar a robustez das variáveis.



Tabela 1: Modelo Logístico Hierárquico

Variável dependente = Óbitos por COVID-19								
Variáveis Explicativas	Dados completos 2020		Dados completos 2021		Imputação 2020		Imputação 2021	
Vacina	-0.43*** (0.09)	-0.43*** (0.09)	-0.68*** (0.09)	-0.67*** (0.09)	-0.25*** (0.09)	-0.25*** (0.09)	-0.52*** (0.06)	-0.52*** (0.06)
Fator de risco	0.55*** (0.05)	0.55*** (0.05)	0.68*** (0.09)	0.68*** (0.06)	0.35*** (0.04)	0.35*** (0.04)	0.47*** (0.03)	0.47*** (0.03)
Escolaridade								
2	0.06 (0.08)	0.05 (0.08)	-0.14** (0.05)	-0.15*** (0.05)	0.10 (0.09)	0.10 (0.09)	-0.14* (0.07)	-0.14* (0.07)
3	-0.37*** (0.05)	-0.37*** (0.05)	-0.41*** (0.07)	-0.42*** (0.07)	-0.28** (0.09)	-0.27** (0.09)	-0.31*** (0.08)	-0.32*** (0.08)
4	-0.76*** (0.07)	-0.75*** (0.08)	-0.61*** (0.14)	-0.62*** (0.14)	-0.61*** (0.15)	-0.60*** (0.15)	-0.47*** (0.12)	-0.48*** (0.12)
Idade	0.04*** (0.00)	0.04*** (0.00)	0.03*** (0.00)	0.03*** (0.00)	0.04*** (0.00)	0.04*** (0.00)	0.03*** (0.00)	0.03*** (0.00)
Sexo	-0.33*** (0.04)	-0.33*** (0.04)	-0.10** (0.05)	-0.10** (0.05)	-0.15*** (0.03)	-0.15*** (0.03)	-0.08** (0.03)	-0.08** (0.03)
Raça								
2	-0.03 (0.12)	-0.04 (0.12)	0.08 (0.14)	0.07 (0.14)	-0.01 (0.10)	-0.01 (0.10)	-0.08 (0.09)	-0.08 (0.09)
3	-0.46** (0.19)	-0.46** (0.19)	-0.07 (0.30)	-0.08 (0.30)	-0.43** (0.16)	-0.43** (0.16)	-0.06 (0.15)	-0.05 (0.15)
4	-0.03 (0.07)	-0.03 (0.07)	-0.02 (0.13)	-0.02 (0.13)	-0.21*** (0.06)	-0.21*** (0.06)	-0.24*** (0.04)	-0.24*** (0.04)
5	0.07 (0.60)	0.04 (0.61)	0.22 (0.45)	0.23 (0.45)	0.18 (0.48)	0.17 (0.48)	-0.07 (0.52)	-0.06 (0.52)
LnPIB		0.10 (0.12)		-0.04 (0.10)		0.03 (0.08)		-0.14* (0.08)
IDH		-3.75*** (1.27)		1.14 (1.35)		-2.90*** (0.90)		2.42** (0.95)
Água		0.01** (0.00)		0.00** (0.00)		0.00*** (0.00)		-0.00*** (0.00)
Lixo		0.00 (0.00)		-0.00*** (0.00)		0.00* (0.00)		-0.00*** (0.00)
Constante	-3.11*** (0.14)	2.79*** (1.01)	-2.38*** (0.17)	-3.20*** (0.88)	-2.64*** (0.12)	-2.50*** (0.06)	-2.17*** (0.14)	-1.84*** (0.62)
OBS	11323	11323	11759	11759	17475	17475	21832	21832
VAR	0.77	0.75	1.08	1.05	0.37	0.34	0.42	0.42

Nota: (***) , (**) , (*) significam que são estatisticamente significativos a 1%, 5% e 10%, respectivamente. Erros padrão robustos entre parênteses

OBS = número de observações

VAR = variância do intercepto aleatório

Os resultados indicam que a variável VACINA foi negativa e estatisticamente significativa em todos os modelos, indicando que aqueles que foram vacinados têm menor probabilidade de morrer por Covid-19 do que os não vacinados. Importante frisar que para o ano de 2020, “Vacina” corresponde a vacina da gripe, ao passo que em 2021 ela se refere à vacina de COVID-19. Note que os parâmetros de 2021 são muito maiores, o que sugere a eficácia da vacina contra COVID-19. Quem se vacinou contra a gripe em 2020 teve menos



chance de vir a óbito do que os não vacinados. Isto pode revelar que os vacinados devem ter maiores cuidados preventivos do que os não vacinados. Portanto, esse resultado está de acordo com o encontrado na literatura que trataram do assunto. Por exemplo, Fink et al. (2021) constataram que os pacientes que receberam uma vacina recente contra influenza tiveram, em média, 7% menos chances de precisar de tratamento intensivo, 17% menos chances de necessitar de suporte respiratório invasivo e 16% menos chance de óbito. Os autores ainda observaram que os efeitos protetores foram maiores quando a vacina foi após o início dos sintomas, bem como entre os pacientes mais jovens.

O desenvolvimento das vacinas corresponde a um grande avanço da humanidade no combate às doenças, tendo como principal objetivo estimular as defesas imunológicas do organismo (Bousada & Pereira, 2017). Neste sentido, os resultados obtidos neste trabalho indicaram menor probabilidade de óbitos entre aqueles que tomaram tanto a vacina antiviral quanto entre aqueles que tomaram o imunizante contra a COVID-19. Em análise preliminar realizada no estado de Mato Grosso, mesmo com o esquema vacinal em fase inicial, evidências apontaram eficácia da vacina contra Covid-19 no quesito redução de mortalidade no grupo prioritário de idosos maiores de 70 anos (Oliveira et al., 2021). Além deste, outros estudos preliminares reforçam a tese de eficácia das vacinas na redução de mortes pelo vírus SARS-CoV-2, conforme pode ser visto ao longo deste capítulo.

Observou-se, também, que os indivíduos com alguma comorbidade (fator de risco) e mais velhos (IDADE) têm maior probabilidade de morrer de Covid-19. Ambas as variáveis se apresentaram positiva e significativa ao nível de 1% de significância. Além disso, o gênero (SEXO) também mostrou-se significativo, indicando que mulheres têm menor probabilidade de morrer de Covid que os homens. Para ambas as variáveis este resultado permaneceu em todos os modelos e, portanto, são robustas. Esse fato também foi constatado por Souza et al. (2021). As explicações para esse achado encontram-se em parte na resposta imunológica que cada sexo biológico apresenta – as mulheres em geral têm uma resposta imune mais vigorosa a infecções, vacinas e algumas doenças malignas. Os homens por sua vez apresentam taxas mais elevadas de comorbidades, tais como doenças cardiovasculares, doenças pulmonares crônicas e hipertensão que representam fatores de risco para o agravamento das complicações causadas pelo Novo Coronavírus (Lotter & Altfeld, 2019; Moreira & Oliveira, 2020).

Foi constatado que os homens figuram o grupo com maior probabilidade de morrer de Covid-19. As divergências entre os gêneros em surtos de doenças e na disparidade em desfechos de saúde compreendem tanto mecanismos físicos, como os fatores biológicos baseados no sexo, que modulam a resposta imune do hospedeiro, quanto perfis socialmente construídos que incluem os aspectos sociais, comportamentais e estilo de vida. Portanto, a COVID-19 não é exceção quando se trata de diferenças de gênero, que se expressam na vulnerabilidade e gravidade da doença e no acesso aos serviços de saúde (OPAS, 2021). Considerando os mecanismos biológicos que combatem as infecções virais, as mulheres, em geral, tendem a produzir uma resposta imune mais eficaz e adaptativa aos vírus, contribuindo para um quadro menos grave da COVID-19 (OPAS, 2021). Outro fator associado a maior taxa de mortalidade por Covid-19 entre pessoas do sexo masculino é a existência de doenças prévias subdiagnosticadas, como hipertensão, diabetes, doença cardiovascular que são, em tese, predominantes entre os homens (PORTO et al., 2021). Além disso, os homens tendem a se envolver em atividades de maior risco que geram potencial para contrair a doença e são mais propensos a minimizar a gravidade do potencial do vírus para prejudicá-los (Griffith et al., 2020).

Quanto à raça, aqueles que se declararam amarelos e pardos apresentaram menor probabilidade de morrer de Covid-19 do que aqueles que se declararam brancos, mas esses



resultados não foram robustos. Então não é possível assegurar sua real associação com a chance de óbito. Porto et al., (2021) em estudo que buscou identificar a mortalidade pela doença no Brasil nas 6 primeiras semanas após a confirmação do primeiro caso de óbito, verificou maior mortalidade entre os indivíduos da cor branca. Entretanto, estudos apontam que a letalidade tem sido maior entre pardos e negros (De Negri et al., 2021; De Lima & Lima, 2021; Galvão & Roncalli, 2021). Conforme evidenciado por Porto et al., (2021), ainda não há hipóteses para tais achados.

Por fim, a variável de interesse – nível de escolaridade – está de acordo com o esperado. Isto é, para os maiores níveis de escolaridade ela mostrou-se negativa e significativa em todos os modelos. Isto indica que quanto maior o nível de escolaridade, menor a probabilidade de se morrer de COVID-19. Este fato pode ser consequência tanto de condições socioeconômicas diferenciadas, que não foram captadas pelo modelo, quanto do aporte maior de conhecimento sobre as formas de prevenção e contenção do vírus, além da possibilidade de adesão às medidas de isolamento social, como por exemplo, adotando o home office (De Negri et al., 2021). Ademais, este resultado mostra-se coerente com o encontrado na literatura, a exemplo de Batista et al. (2020); Pires, Carvalho e Xavier (2020); Borges e Crespo (2020); Pinheiro et al. (2020).

Ao avaliar as variáveis de segundo nível, a maior atenção deve ser dada ao IDHM. Em 2020, quem vivia em municípios com maior IDHM teve menor probabilidade de morrer de Covid-19. Esse resultado está em consonância com estudos que abordaram o tema e o resultado foi igual tanto no modelo geral quanto no reduzido com imputação. Alberti et al. (2021) objetivando verificar a existência de associação entre o maior número de mortes por COVID-19 e o IDH de cidades catarinenses, observaram que as cidades com IDH ruim apresentaram uma taxa de mortes maior em relação às cidades com IDH bom. Em estudo realizado para o estado do Ceará, Araujo et al. (2020) observaram que a predominância de casos e óbitos ocorreu entre a população com IDH baixo e muito baixo. Ressaltando, deste modo, dificuldades no âmbito social.

Contudo, houve uma diferença em relação ao ano de 2021. Para este ano, tanto no modelo com os dados totais quanto no modelo reduzido com imputação notou-se que o parâmetro referente ao IDHM foi positivo, embora significativo apenas no modelo com imputação, cuja amostra é restrita ao mês de pico de casos daquele ano. Este resultado exige maiores investigações que podem ser feitas em estudos futuros. De qualquer modo, talvez no caso dos municípios nordestinos tenha ocorrido uma mudança de padrão de um ano para outro. Na primeira onda¹, os indivíduos que viviam em municípios com maior IDHM tiveram menores chances de morrer de COVID-19, mas é possível que essa lógica tenha se invertido na segunda² onda em função da necessidade da abertura das atividades nas cidades mais desenvolvidas.

Quanto às variáveis de saneamento básico e renda per capita, não apresentaram significância estatística em ambos os períodos analisados, isto é, não foi encontrado evidências da importância que elas exercem no contexto da pandemia, apesar dos trabalhos de Ferreira, Silva e Figueiredo Filho (2021), Chaudhry et al. (2020), Vasconcelos e Muylder (2022) indicarem que são importantes. Entende-se que, em alguma medida, tais indicadores são incorporados no IDHM.

Conforme foi mencionado, a Região Nordeste é caracterizada pela desigualdade socioeconômica e pobreza que reflete em desigualdades entre a população de modo geral. A desigualdade de oportunidades pode alocar os indivíduos em distintas posições

¹ A primeira onda compreende meados de fevereiro até julho 2020.

² A segunda onda compreende meados de novembro de 2020.



socioeconômicas, de acordo com sua raça, gênero, grupo social e sexo, dificultando o acesso à educação, trabalho e renda.

Neste sentido, pessoas mais vulneráveis socioeconomicamente tendem a ser expostas ao vírus de forma diferenciada, porque pessoas nessas situações contam com moradia de pior qualidade, residem em habitações com maior número de pessoas, usam o transporte público com maior aglomeração, possuem ocupações que dificultam adotar as medidas de distanciamento social, além da insegurança alimentar e restrições no acesso aos cuidados médicos, o que propicia taxas mais elevadas de mortes nesse subgrupo populacional (Demenech, et al., 2020).

Populações com baixa renda são mais expostas à contaminação por doenças infecciosas, incluindo pelo SARS-CoV-2, devido à falta de acesso a saneamento básico e à água tratada, à falta de acesso à educação e aos serviços de saúde, à dificuldade de realizarem o isolamento, por morarem em residências precárias ou também por estarem mais frequentemente desempregadas ou engajadas em empregos informais (Kerr et al., 2020). Exatamente neste subgrupo que estão os menos escolarizados. Por isso, Souza et al. (2020) afirmam que esta pandemia tem raça, cor, gênero e classe social.

Com uma parcela da população tendo o privilégio de usufruir das medidas de contenção do vírus sem maiores prejuízos; enquanto a parcela mais vulnerável se vê obrigada a se expor ao vírus para lutar pela sobrevivência. Em síntese, os resultados apresentados destacam a importância da formulação e implementação de políticas públicas na área de Saúde Pública, particularmente em face da probabilidade de novas crises sanitárias. Além disso, considerando a vulnerabilidade desses segmentos da população, tais políticas tornam-se cruciais para mitigar as desigualdades sociais e regionais, protegendo os mais vulneráveis e promovendo a equidade no acesso aos cuidados de saúde.

A análise evidencia que a vacinação desempenha um papel fundamental na redução da mortalidade, sublinhando a necessidade de campanhas de imunização abrangentes e acessíveis. Ademais, as variáveis como comorbidades, idade, gênero e nível de escolaridade revelam papéis distintos na mortalidade por COVID-19, ressaltando a importância de abordagens específicas e direcionadas a esses grupos de risco. Por fim, a influência do Índice de Desenvolvimento Humano Municipal (IDHM) nas taxas de mortalidade sugere a necessidade de políticas regionais sensíveis às disparidades socioeconômicas. Em resumo, a atenção às desigualdades sociais e regionais deve estar no cerne das estratégias de preparação e resposta a crises de saúde pública, garantindo que todos os cidadãos tenham acesso igualitário à proteção e cuidados de saúde.

5. Considerações Finais

Este trabalho teve como objetivo avaliar os fatores associados aos óbitos por COVID-19 nos municípios do nordeste brasileiro. Para obtenção dos resultados, foram estimados modelos logísticos hierárquicos com variáveis a nível individual e ambiental. Conforme pode ser visto, os resultados indicaram significância estatística das variáveis a nível individual em praticamente todos os modelos estimados, nos dois períodos analisados. Quanto às variáveis a nível ambiental, apenas o IDHM apresentou um parâmetro relativamente maior, significativo e conforme o esperado.

Em conformidade com os resultados obtidos, as mulheres têm menor probabilidade de morrer de Covid do que os homens. As explicações para tal achado encontram respaldo em questões biológicas, sociais e culturais. Pessoas idosas e/ou com comorbidades figuram entre os grupos com maior probabilidade de vir a óbito devido à COVID-19. Essas pessoas possuem



o sistema imunológico enfraquecido, levando, portanto, ao aumento da gravidade das doenças infecciosas. Neste sentido, as vacinas desempenham papel fundamental. Como observado, as pessoas vacinadas tanto com a vacina antiviral quanto com a vacina específica para a Covid-19 apresentaram risco menor de morrer em virtude das complicações causadas pela COVID-19.

Quanto à raça, aqueles que se declararam pardos e amarelos têm menor probabilidade de morrer do que aqueles que se declararam brancos. Esse resultado, apesar de encontrar amparo na literatura, divergiu da maioria dos estudos sobre o tema.

Os parâmetros das variáveis que refletem o nível de escolaridade foram significativos; isto indica que os indivíduos mais escolarizados apresentam menor risco de óbito em virtude da COVID-19. Entretanto, esse resultado deve ser analisado cautelosamente, pois não são as pessoas mais escolarizadas que morrem menos simplesmente por ter um nível de escolaridade maior, mas porque essa parcela da população possui poder aquisitivo maior, empregos com condições sanitárias adequadas, habitações com infraestrutura satisfatória. Além de mais acesso à saúde, alimentação de qualidade e hábitos saudáveis. Portanto, essas pessoas dispõem de condições adequadas para aderir às medidas de isolamento e distanciamento social sem maiores prejuízos a sua sobrevivência e desta forma, estão menos suscetíveis à exposição do vírus.

Em relação às variáveis de segundo nível, o Índice de Desenvolvimento Humano Municipal mostrou-se significativo para o ano de 2020 e 2021 quando utilizados os dados totais. Ou seja, municípios que apresentam o melhor indicador, os indivíduos têm menor chance de morrer de COVID-19. As demais variáveis ou não foram significativas ou seus parâmetros foram significativos, mas próximos de zero. Deste modo, no caso dos municípios do Nordeste, não se pode afirmar que as variáveis de saneamento básico e renda per capita tiveram impacto significativo sobre a chance de mortes pelo SARS-CoV-2. Deve-se ressaltar que o resultado para 2021 apresentou divergência ao utilizar os dados totais e imputados. Portanto, tais resultados são mais robustos para a primeira onda no ano de 2020.

A ocorrência de dados faltantes é um problema em pesquisas científicas, principalmente na área da saúde e das Ciências Sociais. Neste sentido, a quantidade de dados faltantes constituiu a principal limitação deste estudo, pois o banco de dados disponibilizado pelo Ministério da Saúde (OpenDataSUS) possuía uma grande quantidade de dados ausentes, sendo necessário recorrer a técnica estatística de imputação de dados. Entretanto, apesar das limitações, foram obtidos resultados satisfatórios e coerente com a literatura que tratou do assunto, conforme foi observado ao longo do texto.

Como agenda para trabalhos futuros, sugere-se considerar nos modelos subsequentes variáveis associadas à estrutura prévia de saúde dos municípios a fim de investigar seus potenciais efeitos sobre os óbitos causados pela pandemia. Ademais, o presente trabalho não capturou as heterogeneidades regionais, pois teve como foco os municípios do Nordeste brasileiro. Assim, a comparação desses resultados com aqueles encontrados em outras regiões pode fornecer importantes *insights* para os formuladores de políticas.

Assim, diante dos resultados obtidos, que este estudo possa subsidiar estratégias e políticas públicas voltadas, principalmente, para os grupos mais vulneráveis econômica e socialmente que tendem a sofrer mais diante das circunstâncias adversas de uma crise.

Referências

- Abreu, M. N. S., Siqueira, A. L., & Caiaffa, W. T. (2009). Regresión logística ordinal en estudios epidemiológicos. *Revista de Salud Pública*, 43(1), 183–194.



- Alberti, A., et al. (2021). Associação do maior número de mortes por COVID-19 e o Índice de Desenvolvimento Humano (IDH) de Cidades Catarinenses/Association of the highest number of deaths by COVID-19 and the Human Development Index (HDI) of cities in Santa Catarina. *ID on line Revista de Psicologia*, 15(54), 427–434.
- Araujo, I. G., et al. (2020). COVID-19 no Estado do Ceará: Impacto do índice de desenvolvimento humano (IDH) na casuística. *Brazilian Journal of Health and Pharmacy*, 2(3), 21–30.
- Balassiano, M., Seabra, A. A., & Lemos, A. H. (2005). Escolaridade, salários e empregabilidade: tem razão a teoria do capital humano? *Revista de Administração Contemporânea*, 9(4), 31–52.
- Barbosa, A. L. N. H., Costa, J. S., & Hecksher, M. (2020). Mercado de trabalho e pandemia da covid-19: Ampliação de desigualdades já existentes? Nota técnica. *Mercado de Trabalho*(69).
- Batista, A., et al. (2020). Análise socioeconômica da taxa de letalidade da COVID-19 no Brasil. *Núcleo de Operações e Inteligência em Saúde (NOIS)*.
- Besarria, V. S. C., et al. (2016). Análise da relação entre escolaridade e a saúde da população brasileira. *Revista Espacios*, 37(2).
<https://www.revistaespacios.com/a16v37n02/16370210.html>
- Borges, G. M., & Crespo, C. D. (2020). Aspectos demográficos e socioeconômicos dos adultos brasileiros e a COVID-19: uma análise dos grupos de risco a partir da Pesquisa Nacional de Saúde, 2013. *Cadernos de Saúde Pública*, 36.
- Bousada, G. M., & Pereira, E. L. (2017). Produção de vacinas virais parte I: engenharia de bioprocessos. *Revista da Universidade Vale do Rio Verde*, 15(1), 309–332.
- Cano, W., & Guimarães Neto, L. (1986). A questão regional no Brasil: Traços gerais de sua evolução histórica. In *Pensamento Iberoamericano. Revista de Economia Política*.
- Campos, L. C., & Miranda, G. J. (2021). Relevância do capital humano para enfrentamento de crises: Um olhar a partir da Teoria do Capital Humano nas organizações em tempos de pandemia. In *21st USP International Conference in Accounting*. São Paulo.
- Chaudhry, R., et al. (2020). A country level analysis measuring the impact of government actions, country preparedness and socioeconomic factors on COVID-19 mortality and related health outcomes. *EClinicalMedicine*, 25, 100464.
- Cruz, A. C., Teixeira, E. C., & Braga, M. J. (2010). Os efeitos dos gastos públicos em infraestrutura e em capital humano no crescimento econômico e na redução da pobreza no Brasil. *Economia, Selecta*, 11(4), 163–185.
- De Lima, A. L. B., & Lima, K. C. (2021). Fatores prognósticos de mortalidade por Covid-19 no Rio Grande do Norte, Brasil. *Revista Brasileira de Ciências da Saúde*, 25(2), 225–234.



Demenech, L. M., et al. (2020). Desigualdade econômica e risco de infecção e morte por COVID-19 no Brasil. *Revista Brasileira de Epidemiologia*, 23.

De Negri, F., et al. (2021). Aspectos socioeconômicos da Covid-19: Evidências dos trabalhadores formais do estado do Rio de Janeiro. *Texto para Discussão*, IPEA.

Ferreira, D., Silva, L., & Figueiredo Filho, D. B. (2021). Saneamento importa? Uma análise da relação entre condições sanitárias e COVID-19 nas capitais brasileiras. *Engenharia Sanitária e Ambiental*, 26, 1079–1084.

Fink, G., et al. (2021). Inactivated trivalent influenza vaccination is associated with lower mortality among patients with COVID-19 in Brazil. *BMJ Evidence-Based Medicine*, 26(4), 192–193.

Galvão, M. H. R., & Roncalli, A. G. (2021). Fatores associados a maior risco de ocorrência de óbito por COVID-19: análise de sobrevivência com base em casos confirmados. *Revista Brasileira de Epidemiologia*, 23.

Griffith, D. M., et al. (2020). Men and COVID-19: A biopsychosocial approach to understanding sex differences in mortality and recommendations for practice and policy interventions. *Preventing Chronic Disease*, 17, E63.

IBGE. (2021). *Pesquisa Nacional por Amostra de Domicílios Contínua*.
<https://www.ibge.gov.br>

IBGE. (2023). *Indicadores sociais municipais: Uma análise dos resultados do universo do Censo Demográfico*.

https://www.ibge.gov.br/home/estatistica/populacao/censo2010/indicadores_sociais_municipais/default_indicadores_sociais_municipais.shtm

IBGE. (2019). *Síntese de Indicadores Sociais*.
<https://biblioteca.ibge.gov.br/visualizacao/livros/liv101678.pdf>

IPEA. (2015). *Índice de Vulnerabilidade Social*. <http://ivs.ipea.gov.br/index.php/pt/>

Kerr, L., et al. (2020). COVID-19 no Nordeste brasileiro: sucessos e limitações nas respostas dos governos dos estados. *Ciência & Saúde Coletiva*, 25, 4099–4120.

Laster Pirtle, W. N. (2020). Racial capitalism: A fundamental cause of novel coronavirus (COVID-19) pandemic inequities in the United States. *Health Education & Behavior*, 47(4), 504–508.

Lopes, T. H. C. R. (2015). *Democracia, confiança e crescimento econômico* (Tese de doutorado). Universidade Federal de Minas Gerais.

Lotter, H., & Altfeld, M. (2019). Sex differences in immunity. In *Seminars in Immunopathology* (pp. 133–135). Springer Berlin Heidelberg.

Ministério da Saúde (BR). (2021). *Boletim epidemiológico especial: Doença pelo coronavírus Covid-19, Semana epidemiológica*, 51 (19/12 a 25/12). <https://www.gov.br/saude/pt-br>



- Moreira, J. A., & Oliveira, C. S. (2020). Tempo e gênero na crise do covid-19. In C. Sales, E. Araújo, & R. Costa (Orgs.), *Tempo e Sociedade em Suspensão* (cap. 11). Lisboa: CIES_Iscte.
- Nunes, L. N. (2007). *Métodos de imputação de dados aplicados na área da saúde* (Tese de doutorado). Universidade Federal do Rio Grande do Sul.
- Oliveira, L. R., et al. (2021). Vacinação contra a covid-19 em Mato Grosso: primeiros resultados. *Instituto de Saúde Coletiva - UFMT. Nota Técnica 02/2021*.
- Organização Pan-Americana da Saúde (OPAS). (2021). *Desfechos de saúde e COVID-19 nas Américas: diferenças de sexo. Janeiro de 2020 a janeiro de 2021*. <https://iris.paho.org/handle/10665.2/53602>
- Peres, I. T., et al. (2021). Sociodemographic factors associated with COVID-19 in-hospital mortality in Brazil. *Public Health*, 192, 15–20.
- Pinheiro, F. M. G., et al. (2020). Iniquidades regionais e sociais na mortalidade por covid-19 no Brasil. *Revista Brasileira de Gestão e Desenvolvimento Regional*, 16(4).
- Pires, L. N., Carvalho, L., & Xavier, L. L. (2020). COVID-19 e desigualdade: a distribuição dos fatores de risco no Brasil. *Experiment Findings*, 21.
- Programa das Nações Unidas para o Desenvolvimento (PNUD). (2019). *Relatório do Desenvolvimento Humano 2019 – Além do rendimento, além das médias, além do presente: Desigualdades no desenvolvimento humano no século XXI*. PNUD.
- Porto, E. F., et al. (2021). Mortalidade por Covid-19 no Brasil: perfil sociodemográfico das primeiras semanas. *Research, Society and Development*, 10(1).
- Raudenbush, S. W., & Bryk, A. S. (2002). *Hierarchical linear models: Applications and data analysis methods* (2nd ed.). Sage Publications.
- Santos, P. R., & Teixeira, N. A. (2022). As sociologias da pandemia: contribuições sobre a Covid-19 e sociedade. *Sociologias*, 24(60), 18–30. <https://doi.org/10.1590/18070337-126449>
- Rossmann, H., et al. (2021). Patterns of COVID-19 pandemic dynamics following deployment of a broad national immunization program. *medRxiv*. <https://doi.org/10.1101/2021.02.08.21251325>
- Rubin, D. B. (1987). *Multiple imputation for nonresponse in surveys*. John Wiley & Sons.
- Silva, V. V. A. (2021). A COVID-19 enquanto questão social: classe, escolaridade e cor da pandemia no Pará. *Holos*, 1, 1–14.
- Soares, T. M., & Mendonça, M. C. M. (2003). Construção de um modelo de regressão hierárquico para os dados do SIMAVE-2000. *Pesquisa Operacional*, 23(3), 421–441.



- Souza, F. S. H., et al. (2021). On the analysis of mortality risk factors for hospitalized COVID-19 patients: A data-driven study using the major Brazilian database. *PLOS ONE*, 16(3). <https://doi.org/10.1371/journal.pone.0248580>
- Souza, L. P., et al. (2020). COVID-19 no Brasil: seguimos no mesmo mar, mas não nos mesmos barcos. *Comunicação em Ciências da Saúde*, 31(3), 41–48.
- Van Buuren, S. (2007). Multiple imputation of discrete and continuous data by fully conditional specification. *Statistical Methods in Medical Research*, 16(3), 219–242.
- Van Buuren, S., & Oudshoorn, K. (1999). *Flexible multivariate imputation by MICE*. Leiden: TNO.
- Vasconcelos, I. M. P., & Muyllder, C. F. (2022). Os vazios institucionais, saneamento e déficit de água e os primeiros números Covid-19 no Brasil. *Revista de Administração da UFSM*, 14, 1221–1238.
- World Bank. (2021). *Global economic prospects, June 2021*.
<https://www.worldbank.org/pt/publication/global-economic-prospects>
- Zhang, P. (2003). Multiple imputation: Theory and method. *International Statistical Review*, 71(3), 581–592.

ⁱ Mestre em Economia pela Universidade Federal de Sergipe (UFS). Técnico Administrativo do Departamento de Computação da Universidade Federal de Sergipe (UFS). (79) 3194-6678. Cidade Universitária Prof Aloísio de Campos, São Cristóvão/SE.

ⁱⁱ Doutor em Economia pela Universidade Federal de Minas Gerais. Professor Adjunto do Departamento de Economia da Universidade Federal de Sergipe (UFS) – São Cristóvão – SE.

ⁱⁱⁱ Doutora em Desenvolvimento Econômico pela Universidade Federal do Paraná (UFPR). Professora Associada do Departamento de Economia da Universidade Federal de Sergipe (UFS). Cidade Universitária Prof Aloísio de Campos , Jardim Rosa Elze, São Cristóvão/SE.

