

UNIVERSIDADE FEDERAL DE MINAS GERAIS

Instituto de Geociências

Programa de Pós-graduação em Análise e Modelagem de Sistemas Ambientais

Matheus Luiz Jorge Cortez

MODELAGEM DA VULNERABILIDADE À COVID-19 EM MINAS GERAIS: influências
socioeconômicas

Belo Horizonte

2025

Matheus Luiz Jorge Cortez

MODELAGEM DA VULNERABILIDADE À COVID-19 EM MINAS GERAIS:
INFLUÊNCIAS SOCIOECONÔMICAS

Tese apresentada ao Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais, como requisito parcial à obtenção do título de Doutor em Análise e Modelagem de Sistemas Ambientais.

Orientadora: Profa. Dra. Úrsula Ruchkys de Azevedo

Belo Horizonte

2025

C828m
2025

Cortez, Matheus Luiz Jorge.

Modelagem da vulnerabilidade à COVID-19 em Minas Gerais [manuscrito] :
influências socioeconômicas / Matheus Luiz Jorge Cortez. – 2025.
113 f., enc. il. (principalmente color.)

Orientadora: Úrsula Ruchkys de Azevedo.

Tese (doutorado) – Universidade Federal de Minas Gerais, Instituto de
Geociências, 2025.

Bibliografia: f. 102-113.

1. Modelagem de dados – Aspectos ambientais – Teses. 2. COVID-19
(Doença) – Minas Gerais – Teses. 3. Bibliometria – Teses. 4. Análise espacial
(Estatística) – Teses. 5. Processo decisório por critério múltiplo – Teses. I.
Ruchkys, Úrsula de Azevedo. II. Universidade Federal de Minas Gerais. Instituto
de Geociências. III. Título.

CDU: 911.2:519.6(815.1)



UNIVERSIDADE FEDERAL DE MINAS GERAIS INSTITUTO DE GEOCIÊNCIAS COLEGIADO DE PÓS-GRADUAÇÃO EM ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS

FOLHA DE APROVAÇÃO

MODELAGEM DA VULNERABILIDADE À COVID-19 EM MINAS GERAIS: INFLUÊNCIAS SOCIOECONÔMICAS

MATHEUS LUIZ JORGE CORTEZ

Tese de Doutorado defendida e aprovada, no dia vinte e quatro de março de dois mil e vinte cinco, pela Banca Examinadora designada pelo Colegiado de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais constituída pelos seguintes professores:

Camila Palhares Teixeira

Universidade do Estado de Minas Gerais

Michel Eustáquio Dantas Chaves

Universidade Estadual Paulista Júlio de Mesquita F

Jorge Batista de Souza

Pontifícia Universidade Católica de Minas Gerais

Selma Costa de Souza

Secretaria de Saúde da Prefeitura de Contagem

Úrsula Ruchkys de Azevedor

Universidade Federal de Minas Gerais

Belo Horizonte, 25 de março de 2025.



Documento assinado eletronicamente por **Jorge Batista de Souza, Usuário Externo**, em 26/03/2025, às 08:01, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Camila Palhares Teixeira, Usuário Externo**, em 26/03/2025, às 14:46, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ursula Ruchkys de Azevedo, Professor(a)**, em 26/03/2025, às 14:55, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Selma Costa de Sousa, Usuária Externa**, em 31/03/2025, às 10:23, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Michel Eustáquio Dantas Chaves, Usuário Externo**, em 03/04/2025, às 17:41, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4074123** e o código CRC **20DA51E3**.

AGRADECIMENTOS

Expresso meus sinceros agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio concedido durante o desenvolvimento deste doutorado.

À minha orientadora, Profa. Dra. Úrsula Ruchkys de Azevedo, manifesto minha profunda gratidão pelo conhecimento compartilhado, pela orientação criteriosa e pela paciência ao longo desta jornada acadêmica.

À minha amada mãe, um exemplo de força e generosidade, que iluminou cada ambiente por onde passou. Mesmo nos momentos mais difíceis, soube enfrentar a vida com leveza e bom humor. Seu amor incondicional pelos filhos foi retribuído com igual intensidade.

Ao meu pai, cuja dedicação e compromisso sempre garantiram o melhor para seus filhos, permitindo que pudessem crescer e contribuir para o progresso da sociedade.

À minha companheira, Agnis Cristiane de Souza, que, ao longo dos últimos sete anos, tem sido uma parceira incrível. Seu apoio incondicional e sua presença constante foram fundamentais nos momentos mais desafiadores desta trajetória.

Por fim, expresso minha gratidão a todos os membros da banca, cujo tempo, dedicação e valiosas contribuições foram essenciais para a finalização deste trabalho.

*“A verdadeira motivação vem de realização, desenvolvimento pessoal,
satisfação no trabalho e reconhecimento”*

Frederick Herzberg

RESUMO

Esta tese investiga a vulnerabilidade dos municípios mineiros à disseminação da COVID-19 em função de fatores socioeconômicos. Para isso, integra abordagens bibliométricas, estatísticas espaciais e modelagem multicritério, fornecendo uma análise abrangente da distribuição da doença e de seus determinantes estruturais. O estudo é estruturado em três eixos interdependentes. O primeiro eixo realizou uma análise bibliométrica da produção científica sobre os impactos socioeconômicos da COVID-19 em três níveis geográficos: global, nacional (Brasil) e regional (Minas Gerais). Foram analisados artigos das bases Scopus e Web of Science por meio dos pacotes *pubmedR* e *bibliometrix* no ambiente R. Os resultados indicaram uma desaceleração da produção científica global (-38,77%) e nacional (-55,91%), contrastando com um crescimento expressivo nos estudos regionais (+41,42%). A análise revelou a centralidade de países como Estados Unidos, Reino Unido e China na colaboração científica e destacou o predomínio de pesquisas sobre grupos vulneráveis, mercado de trabalho, pobreza e saúde mental. Essa etapa permitiu identificar lacunas que orientaram a investigação empírica dos eixos seguintes. O segundo eixo aplicou análises espaciais para investigar a relação entre fatores socioeconômicos e a disseminação da COVID-19 em Minas Gerais. Foram construídos modelos de regressão espacial, incluindo *spatial error models* (SEMs) e *spatial lag models* (SLMs), a partir de do Instituto de Pesquisa Econômica Aplicada (IPEA). Os resultados demonstraram que municípios com maior longevidade e melhor infraestrutura urbana apresentaram menores taxas de mortalidade. Essa etapa revelou padrões espaciais de autocorrelação forneceu suportes à formulação de estratégias para mitigação de riscos e otimização da alocação de recursos médicos. No terceiro eixo, os achados anteriores foram integrados para a modelagem multicritério da vulnerabilidade municipal à COVID-19, considerando variáveis socioeconômicas, estruturais e epidemiológicas. Utilizando um modelo de análise multicritério (ADMC), os 853 municípios mineiros foram classificados segundo seu risco de transmissão. Os resultados indicaram que Belo Horizonte, Uberlândia e Contagem apresentaram maior vulnerabilidade devido à alta densidade populacional, conectividade rodoviária e predominância de empregos no setor de comércio e serviços. A urbanização foi o fator mais influente na disseminação do vírus (22,92%), seguida pela conectividade rodoviária (17,54%). A validação cruzada aprimorou a capacidade preditiva da análise, reforçando a necessidade de abordagens interdisciplinares na formulação de políticas públicas. Ao integrar esses três eixos, a tese evidencia como a combinação de diferentes abordagens analíticas – da produção científica à modelagem espacial e multicritério – permite uma compreensão aprofundada da vulnerabilidade municipal à COVID-19. Os resultados reforçam a necessidade de políticas baseadas em evidências e demonstram a importância da integração entre epidemiologia, geoinformação e gestão pública para o enfrentamento de emergências sanitárias.

Palavras-chave: análise bibliométrica; COVID-19; fatores socioeconômicos; modelagem espacial; análise de decisão multicritério.

ABSTRACT

This thesis investigates the vulnerability of municipalities in Minas Gerais to the spread of COVID-19 due to socioeconomic factors. To this end, it integrates bibliometric approaches, spatial statistics, and multicriteria modeling, providing a comprehensive analysis of the distribution of the disease and its structural determinants. The study is structured along three interdependent axes. The first axis carried out a bibliometric analysis of scientific production on the socioeconomic impacts of COVID-19 at three geographic levels: global, national (Brazil), and regional (Minas Gerais). Articles from the Scopus and Web of Science databases were analyzed using the pubmedR and bibliometrix packages in the R environment. The results indicated a slowdown in global (-38.77%) and national (-55.91%) scientific production, contrasting with a significant growth in regional studies (+41.42%). The analysis revealed the centrality of countries such as the United States, the United Kingdom, and China in scientific collaboration and highlighted the predominance of research on vulnerable groups, the labor market, poverty, and mental health. This stage allowed us to identify gaps that guided the empirical investigation of the following axes. The second axis applied spatial analyses to investigate the relationship between socioeconomic factors and the spread of COVID-19 in Minas Gerais. Spatial regression models, including spatial error models (SEMs) and spatial lag models (SLMs), were constructed based on data from the Institute of Applied Economic Research (IPEA). The results showed that municipalities with greater longevity and better urban infrastructure had lower mortality rates. This stage revealed spatial patterns of autocorrelation that provided support for the formulation of strategies to mitigate risks and optimize the allocation of medical resources. In the third axis, the previous findings were integrated for multicriteria modeling of municipal vulnerability to COVID-19, considering socioeconomic, structural, and epidemiological variables. Using a multicriteria analysis model (MCA), the 853 municipalities in Minas Gerais were classified according to their risk of transmission. The results indicated that Belo Horizonte, Uberlândia and Contagem were more vulnerable due to their high population density, road connectivity and predominance of jobs in the trade and services sector. Urbanization was the most influential factor in the spread of the virus (22.92%), followed by road connectivity (17.54%). Cross-validation improved the predictive capacity of the analysis, reinforcing the need for interdisciplinary approaches in the formulation of public policies. By integrating these three axes, the thesis shows how the combination of different analytical approaches – from scientific production to spatial and multicriteria modeling – allows for an in-depth understanding of municipal vulnerability to COVID-19. The results reinforce the need for evidence-based policies and demonstrate the importance of integrating epidemiology, geoinformation and public management to address health emergencies.

Keywords: bibliometric analysis; COVID-19; multicriteria decision analysis; socioeconomic factors; spatial modeling.

LISTA DE ILUSTRAÇÕES

FIGURA 1.1 – FLUXOGRAMA COM SEQUENCIA METODOLÓGICA APLICADA NA TESE.....	27
FIGURA 2.1 – PRINCIPAIS REVISTAS COM PUBLICAÇÕES SOBRE AS RELAÇÕES ENTRE A COVID-19 E FATORES SOCIOECONÔMICOS EM ÂMBITO GLOBAL.....	35
FIGURA 2.2 – PRINCIPAIS REVISTAS COM PUBLICAÇÕES SOBRE AS RELAÇÕES ENTRE A COVID-19 E FATORES SOCIOECONÔMICOS NO CONTEXTO BRASILEIRO	37
FIGURA 2.3 – ESPACIALIZAÇÃO DA PRODUÇÃO CIENTÍFICA POR PAÍS	39
FIGURA 2.4 – ESPACIALIZAÇÃO DAS PRODUÇÕES CIENTÍFICAS POR NACIONALIDADE DOS AUTORES CORRESPONDENTES.....	40
FIGURA 2.5 – PAÍSES COM O MAIOR NÚMERO AUTORES CORRESPONDENTES E COLABORAÇÕES INTERNACIONAIS ..	41
FIGURA 2.6 – REDE DE CONEXÕES DOS DEZ PAÍSES MAIS CONECTADOS	43
FIGURE 3.1 – MAP OF THE LOCATION OF MINAS GERAIS, BRAZIL.	51
FIGURE 3.1 – SPATIALIZATION OF COVID-19 DATA IN THE STATE OF MINAS GERAIS, BRAZIL. DATA ACCUMULATED FROM MARCH 2020 TO THE END OF OCTOBER 2020. A) DISTRIBUTION OF CASES DUE TO SARS-CoV-2 INFECTION. B) DISTRIBUTION OF DEATHS.....	55
FIGURE 3.2 – GLOBAL MORAN SCATTER PLOT FOR VARIABLES OF CASES AND DEATHS FROM SARS-CoV-2 IN THE STATE OF MINAS GERAIS, BRAZIL (MAR-OCT. 2020).	55
FIGURE 3.3 – SPATIAL AUTOCORRELATION IN THE FIRST WAVE OF COVID-19 IN THE STATE OF MINAS GERAIS, BRAZIL. 4A. AUTOCORRELATION MAP OF CASES. 4B. AUTOCORRELATION MAP OF DEATHS.....	56
FIGURA 4.1 – FLUXOGRAMA SIMPLIFICADO DA METODOLOGIA DESENVOLVIDA.	67
FIGURA 4.1 – NÍVEIS DO $IVT_{SARS-CoV-2}$ PARA OS MUNICÍPIOS DE MINAS GERAIS.....	72
FIGURA 4.2 – NÍVEIS DO $IVT_{SARS-CoV-2}$ E MICRORREGIÕES DE MAIOR VULNERABILIDADE NO ÂMBITO DE MINAS GERAIS.....	73
FIGURA 5.1 – GRÁFICO DE DISPERSÃO DE MORAN I PARA OS CASOS DE COVID-19 EM JULHO DE 2020	84
FIGURA 5.2 – GRÁFICO DE DISPERSÃO DE MORAN I PARA OS CASOS DE COVID-19 EM ABRIL DE 2021.....	85
FIGURA 5.3 – GRÁFICO DE DISPERSÃO DE MORAN I PARA OS CASOS DE COVID-19 EM FEVEREIRO DE 2022.....	85
FIGURA 5.4 – PADRÕES LOCAIS DE AUTOCORRELAÇÃO ESPACIAL EM JULHO DE 2020.....	87
FIGURA 5.5 – PADRÕES LOCAIS DE AUTOCORRELAÇÃO ESPACIAL EM ABRIL DE 2021	87
FIGURA 5.6 – PADRÕES LOCAIS DE AUTOCORRELAÇÃO ESPACIAL EM FEVEREIRO DE 2022	88

LISTA DE TABELAS

TABELA 2.1 – PRINCIPAIS RESULTADOS DA ANÁLISE BIBLIOMÉTRICA NAS ESFERAS DE ESTUDO	33
TABELA 2.2 – PRINCIPAIS PALAVRAS-CHAVE ENCONTRADAS NOS ARTIGOS CIENTÍFICOS.....	44
TABELA 2.3 – PRINCIPAIS UNIVERSIDADES EM RELAÇÃO À PRODUÇÃO CIENTÍFICA SOBRE O TEMA	45
TABELA 2.4 – REPRESENTAÇÃO GEOGRÁFICAS DAS UNIVERSIDADES MAIS PRODUTIVAS	46
TABLE 3.1 – SUMMARY OF THE VARIABLES.	52
TABLE 3.1 – OLS REGRESSION FOR THE DEPENDENT VARIABLE CASES.	56
TABLE 3.2 – OLS REGRESSION FOR THE DEPENDENT VARIABLE DEATHS.....	57
TABLE 3.3 – LAGRANGE MULTIPLIER TEST.....	57
TABLE 3.4 – SPATIAL ERROR MODEL FOR THE DEPENDENT VARIABLE CASES	58
TABLE 3.5 – SPATIAL ERROR MODEL FOR THE DEPENDENT VARIABLE DEATHS	58
TABLE 3.6 – SPATIAL LAG MODEL FOR THE DEPENDENT VARIABLE CASES	59
TABLE 3.7 – SPATIAL LAG MODEL FOR THE DEPENDENT VARIABLE DEATHS	59
TABLE 3.8 – SPATIAL LAG MODEL IMPACT TESTS FOR CASES.....	59
TABLE 3.9 – SPATIAL LAG MODEL IMPACT TESTS FOR DEATHS.....	60
TABELA 4.1 – VALORES DAS CORRELAÇÕES DE PEARSON COM A VARIÁVEL DEPENDENTE C-COV, PERCENTUAL CORRESPONDENTE A CADA VARIÁVEL DE ACORDO COM A SOMA DOS VALORES DA CORRELAÇÃO E PESOS CALCULADOS PARA CADA VARIÁVEL.	72
TABELA 4.2 – MUNICÍPIOS COM OS MAIORES VALORES DE $IVT_{SARS-CoV-2}$ DE ACORDO COM O MODELO PROPOSTO.	74
TABELA 5.1 – VARIÁVEIS EXPLICATIVAS UTILIZADAS PARA MODELAGEM.....	81
TABELA 5.1 – TESTE MULTIPLICADOR DE LAGRANGE.....	89
TABELA 5.2 – MODELO OLS PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM JULHO DE 2020	89
TABELA 5.3 – MODELO SEM PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM JULHO DE 2020.....	90
TABELA 5.4 – MODELO SARMA PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM JULHO DE 2020.....	90
TABELA 5.5 – MODELO OLS PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM ABRIL DE 2021	91
TABELA 5.6 – MODELO SEM PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM ABRIL DE 2021	91
TABELA 5.7 – MODELO SAR PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM ABRIL DE 2021	91
TABELA 5.8 – MODELO SARMA PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM ABRIL DE 2021	92
TABELA 5.9 – MODELO OLS PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM FEVEREIRO DE 2022	92
TABELA 5.10 – MODELO SEM PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM FEVEREIRO DE 2022	93
TABELA 5.11 – MODELO SAR PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM FEVEREIRO DE 2022.....	93
TABELA 5.12 – MODELO SARMA PARA VARIÁVEL DEPENDENTE CASOS DE COVID -19 EM FEVEREIRO DE 2022	93
TABELA 5.13 – IMPACTOS DO MODELO SARMA PARA O PERÍODO DE JULHO DE 2020	95
TABELA 5.14 – IMPACTOS DO MODELO SARMA PARA O PERÍODO DE ABRIL DE 2021	95
TABELA 5.15 – IMPACTOS DO MODELO SARMA PARA O PERÍODO DE FEVEREIRO DE 2022.....	96

SUMÁRIO

1 INTRODUÇÃO GERAL	13
1.1 CONTEXTUALIZAÇÃO E RELEVÂNCIA DO TEMA	13
1.2 JUSTIFICATIVA E LACUNA NA LITERATURA	14
1.3 OBJETIVOS DA PESQUISA	17
1.4 METODOLOGIAS APLICADAS E DESENVOLVIDAS	17
1.4.1 Análise Bibliométrica Comparativa	18
1.4.2 Modelagem Estatística Espacial: Autocorrelação e Regressões.....	19
1.4.3 Construção do Índice de Vulnerabilidade à Transmissibilidade do SARS-CoV-2 (IVT _{SARS-CoV-2})	22
1.5 PRODUTOS DA TESE DE DOUTORADO	25
1.6 ESTRUTURA DA TESE	28
2 FATORES SOCIOECONÔMICOS E COVID-19: UMA ANÁLISE BIBLIOMÉTRICA	29
2.1 INTRODUÇÃO.....	30
2.2 MÉTODOS.....	31
2.2.1 Abordagem geral	31
2.2.2 Coleta de dados.....	31
2.2.3 Processamento e análise de dados	32
2.2.4 Comparação entre diferentes níveis geográficos	32
2.2.5 Limitações do estudo	32
2.3 RESULTADOS E DISCUSSÕES.....	33
2.3.1 Principais resultados.....	33
2.3.2 Principais periódicos nos contextos global e nacional	34
2.3.3 Análise dos dados no contexto global	39
2.3.3.1 principais países em termos de produções científicas sobre os impactos socioeconômicos da COVID-19	39
2.3.3.2 Cooperação internacional.....	41
2.3.3.3 Redes de conexões entre os países.....	42
2.3.3.4 Palavras-chave mais utilizadas	43
2.3.3.5 Representação geográfica das universidades mais produtivas	45
2.4 CONCLUSÕES	46
3 WHAT ROLE DO SOCIAL VARIABLES AND HEALTH PLAY IN THE SPREAD OF COVID-19 IN THE STATE OF MINAS GERAIS – BRAZIL?	48

3.1 INTRODUCTION	49
3.2 METHODS	50
3.2.1 Characterization	50
3.2.2 Description of the Study Area	51
3.2.3 Variables considered in the study	51
3.2.4 Statistical analyses	53
3.2.4.1 <i>Spatial autocorrelation of the COVID-19 cases and deaths dependent variables</i>	53
3.2.4.2 <i>Regression models</i>	54
3.3 RESULTS	54
3.4 DISCUSSION	60
3.5 CONCLUSIONS	63
4 IVT_{SARS-COV-2}: UM ÍNDICE MULTICRITÉRIO E A DINÂMICA URBANA EM MINAS GERAIS, BRASIL	64
4.1 INTRODUÇÃO	65
4.2 METODOLOGIA	66
4.2.1 Dados da COVID-19	67
4.2.1 Dados de cobertura do solo – corredores	67
4.2.1.1 <i>Rasterização dos dados de corredores</i>	68
4.2.3 Dados de cobertura do solo – área urbana	68
4.2.4 Dados socioeconômicos	69
4.2.5 Modelo de análise multicritério	69
4.2.5 Validação cruzada	71
4.3 RESULTADOS	71
4.4 DISCUSSÕES	74
4.5 CONSIDERAÇÕES FINAIS	77
5 MODELAGEM ESPACIAL DA DISSEMINAÇÃO DA COVID-19 EM MINAS GERAIS: ANÁLISE DAS TRÊS PRIMEIRAS ONDAS E FATORES SOCIOECONÔMICOS	78
5.1 INTRODUÇÃO	79
5.2 METODOLOGIA	80
5.2.1 Base de Dados e Pré-processamento	80
5.2.2 Desenvolvimento dos modelos	81
5.2.3 Definição da Matriz de Vizinhança	82

5.2.4 Testes de Dependência Espacial.....	82
5.2.5 Especificação dos Modelos	82
5.2.6 Cálculo de Impactos Espaciais e Visualização dos Dados	83
5.3 RESULTADOS E DISCUSSÕES.....	83
5.3.1 Análise Local da Dependência Espacial: Identificação de Clusters.....	86
5.3.2 Modelagem Espacial e Comparação dos Modelos	88
5.3.3 Testes de impactos dos modelos SARMA	93
5.4 CONCLUSÃO.....	96
6 CONCLUSÃO GERAL	98
REFERÊNCIAS	102

1 INTRODUÇÃO GERAL

1.1 CONTEXTUALIZAÇÃO E RELEVÂNCIA DO TEMA

A pandemia da COVID-19, causada pelo vírus SARS-CoV-2, representou um dos maiores desafios sanitários da história contemporânea. Desde os primeiros casos registrados em dezembro de 2019 na cidade de Wuhan, China, a doença se espalhou rapidamente pelo mundo, resultando em milhões de mortes e provocando crises sanitárias, econômicas e sociais sem precedentes (HUI et al., 2020; WU; LEUNG; LEUNG, 2020). Em 11 de março de 2020, a Organização Mundial da Saúde (OMS) classificou a COVID-19 como uma pandemia, destacando a necessidade de ações coordenadas entre países para mitigar seus impactos (WHO, 2020).

Além do impacto direto na saúde pública, a crise global exacerbou desigualdades sociais, econômicas e estruturais, afetando milhões de pessoas em todo o mundo (MENA et al., 2021; NICOLA et al., 2020). Fatores como renda, escolaridade, acesso a serviços de saúde e infraestrutura urbana desempenharam um papel crucial na disseminação do vírus e nas taxas de mortalidade (BAENA-DÍEZ et al., 2020; PATEL et al., 2020).

O Brasil tornou-se um dos epicentros da pandemia, registrando números alarmantes de casos e óbitos. Até fevereiro de 2025, o país contabilizava 39.204.051 casos e 715.261 mortes em decorrência da COVID-19 (MINISTÉRIO DA SAÚDE, 2025). Em Minas Gerais, um dos estados mais afetados, o número de casos confirmados ultrapassava 4,3 milhões, com 66.896 óbitos (SES-MG, 2025a). Diante dessas desigualdades regionais e estruturais, é essencial aprofundar o conhecimento sobre os determinantes socioeconômicos da vulnerabilidade à COVID-19, considerando abordagens metodológicas que integrem aspectos espaciais e sociais.

Minas Gerais, devido à sua grande extensão territorial, diversidade socioeconômica e elevada heterogeneidade no acesso a serviços de saúde, representa um cenário particularmente relevante para a investigação dessas relações. Identificar os fatores que ampliam ou reduzem a vulnerabilidade dos municípios mineiros à COVID-19 pode contribuir para o desenvolvimento de estratégias mais eficientes de mitigação e resposta a futuras emergências sanitárias.

A dinâmica de disseminação da COVID-19 em Minas Gerais pode ter sido influenciada pela evolução das variantes do SARS-CoV-2. Na primeira onda da pandemia, predominavam variantes pré-VOC (pré-Variants of Concern), associadas a uma menor taxa de transmissão. A partir da segunda onda, observou-se a circulação de variantes de preocupação, como Alpha, Beta, Gamma e Delta, marcadas por maior transmissibilidade e potencial de escape

imunológico. No terceiro pico, a variante Ômicron tornou-se dominante, destacando-se por sua alta capacidade de infecção e rápida propagação entre a população (MARKOV et al., 2023). As mudanças no perfil genético do vírus ao longo do tempo podem ter alterado significativamente os padrões espaciais e temporais da transmissão, com implicações diretas sobre a efetividade das medidas de controle e sobre a resposta imunológica coletiva.

Ao se avaliar as características populacionais relacionadas à vulnerabilidade das sociedades à transmissão viral, observa-se que vários fatores socioeconômicos desempenham um papel determinante na dinâmica de disseminação e nos desfechos da COVID-19. Variáveis como escolaridade, renda, estrutura do mercado de trabalho e acesso aos serviços de saúde influenciam diretamente nos modos de transmissão e letalidade da doença (ARAÚJO; BRANDÃO, 2021; BAENA-DÍEZ et al., 2020). Além disso, condições associadas à insegurança habitacional, como moradias superlotadas e infraestrutura de saúde precária, também se mostraram relevantes na disseminação do vírus, particularmente em contextos urbanos marcados por desigualdades socioespaciais (MAROKO; NASH; PAVILONIS, 2020; VON SEIDLEIN et al., 2021).

1.2 JUSTIFICATIVA E LACUNA NA LITERATURA

Desde o início da pandemia da COVID-19, pesquisadores têm se dedicado a compreender os fatores que influenciam a disseminação do vírus e seus impactos sobre diferentes populações. Embora a literatura sobre a COVID-19 tenha avançado significativamente, ainda há lacunas importantes na compreensão integrada da vulnerabilidade municipal, especialmente em relação aos determinantes socioeconômicos e ambientais. A maioria dos estudos existentes adota abordagens fragmentadas, priorizando aspectos epidemiológicos ou socioeconômicos de forma isolada, sem considerar a complexidade das interações entre fatores estruturais, mobilidade populacional e desigualdades socioespaciais.

Estudos demonstram que fatores como nível educacional, renda, ocupação, acesso à saúde e estrutura do mercado de trabalho exercem influência direta na transmissão e letalidade da COVID-19 (AHMED et al., 2020; PATEL et al., 2020). De Angelis et al. (2021), por exemplo, analisaram 1.439 municípios na região da Lombardia, Itália, e identificaram que municípios com maior taxa de escolaridade apresentaram menor taxa de transmissão do SARS-CoV-2. Além disso, características como o uso predominante de transporte privado e a maior distância até hospitais estiveram associadas a um menor número de casos, enquanto municípios

com elevada concentração de trabalhadores em setores de atendimento ao público (bares, restaurantes, esportes e lazer) registraram maiores taxas de infecção.

No contexto dos Estados Unidos, Quan et al. (2021) analisaram a relação entre a COVID-19 e fatores socioeconômicos em 2.038 pacientes hospitalizados no sudeste de Michigan e identificaram disparidades raciais e econômicas significativas. Os autores relataram que 59,3% dos pacientes hospitalizados eram negros, apesar de essa população representar uma parcela menor da população local. Além disso, os pacientes negros que vieram a óbito devido à COVID-19 tinham uma média de idade inferior à dos pacientes brancos (61,7 anos e 68,6 anos, respectivamente), evidenciando um impacto desproporcional sobre populações vulneráveis. A pesquisa também apontou que pacientes que necessitaram de ventilação mecânica invasiva ou internação em terapia intensiva eram predominantemente residentes de bairros com menor renda média, menor nível educacional e maior insegurança alimentar.

O impacto da pandemia sobre o distanciamento social também foi analisado por Garnier et al. (2021), que estudaram 3.054 condados dos EUA utilizando dados de localização via GPS. Os autores identificaram que em condados com maior proporção de população em situação de pobreza e maior presença de trabalhadores essenciais (setor alimentício, transportes e saúde), o distanciamento social foi menos eficaz. Em contrapartida, condados com maior densidade populacional e maior proporção de pessoas negras demonstraram maior adesão às restrições de circulação, evidenciando padrões distintos de comportamento social durante a crise sanitária.

Cifuentes et al. (2021) analisaram a desigualdade social e os impactos demográficos da COVID-19 na Colômbia e encontraram um risco significativamente maior de morte entre homens (57%) do que entre mulheres. O estudo também revelou que populações indígenas apresentaram 27% mais risco de morte em comparação ao restante da população e que indivíduos dependentes de serviços de saúde pública subsidiados tinham um risco de morte 97% maior. Esses achados demonstram a relação direta entre condições socioeconômicas e desfechos clínicos da COVID-19, destacando o papel da desigualdade estrutural no agravamento da pandemia.

Em um estudo sobre disparidades urbanas, Maroko, Nash e Pavilonis (2020) analisaram áreas de alto risco (hot-spots) e baixo risco (cold-spots) para a COVID-19 em Nova York e Chicago e concluíram que o número de habitantes por domicílio era mais relevante para a disseminação do vírus do que a densidade populacional global. Em Nova York, os hot-spots eram habitados por trabalhadores essenciais com renda média acima da média da cidade, enquanto em Chicago, os hot-spots estavam associados a bairros de maior pobreza e elevada taxa de desemprego (18%). Já as áreas classificadas como cold-spots eram habitadas por

indivíduos com maior nível educacional, maior renda e maior proporção de trabalhadores em cargos gerenciais, sugerindo uma maior resiliência dessas populações às restrições impostas pela pandemia.

Esses estudos demonstram que a vulnerabilidade à COVID-19 não pode ser explicada por um único fator, pois resulta da interação entre condições socioeconômicas, fatores ambientais e infraestrutura urbana. No entanto, a maior parte da literatura existente ainda se concentra em análises pontuais, sem integrar metodologias mais avançadas, como modelagem espacial e análise multicritério, que permitiriam um diagnóstico mais robusto e territorialmente explícito (ANDERSEN et al., 2021; GARNIER et al., 2021).

Além disso, é essencial que as pesquisas sobre COVID-19 estejam alinhadas às diretrizes globais de desenvolvimento sustentável. O Objetivo de Desenvolvimento Sustentável 3 (ODS-3) da ONU propõe "garantir o acesso à saúde de qualidade e promover o bem-estar para todos, em todas as idades" (ONU, 2022). Dentro desse contexto, o subitem 3.d enfatiza a necessidade de fortalecer a capacidade dos países para alerta precoce, redução de riscos e gerenciamento de crises sanitárias. Assim, a presente pesquisa contribui para esse objetivo ao propor um modelo analítico que possibilite mapear a vulnerabilidade dos municípios mineiros, subsidiando políticas públicas eficazes no enfrentamento de futuras pandemias.

Diante dessa lacuna teórica e metodológica, a presente tese busca responder à seguinte questão central: quais fatores socioeconômicos determinam a vulnerabilidade dos municípios mineiros à disseminação da COVID-19 e como metodologias integradas podem ser utilizadas para mapear essa vulnerabilidade e subsidiar políticas públicas mais eficazes?

Para responder a essa questão, a pesquisa estrutura-se em quatro eixos analíticos complementares, que combinam análise bibliométrica, modelagem estatística espacial, desenvolvimento de um índice de vulnerabilidade à COVID-19 e modelagem estatística espaço-temporal. Esses eixos permitem uma compreensão abrangente da relação entre as características socioeconômicas e ambientais dos municípios e os impactos da pandemia, fornecendo subsídios para a formulação de estratégias mais eficazes de mitigação de riscos sanitários.

No entanto, algumas dificuldades foram enfrentadas durante a realização da pesquisa, especialmente no que diz respeito ao acesso a dados mais detalhados, em razão das restrições impostas pela legislação de proteção de dados vigente no Brasil. A Lei Geral de Proteção de Dados Pessoais (LGPD – Lei nº 13.709/2018) estabelece diretrizes para o tratamento de dados pessoais, com o objetivo de proteger os direitos fundamentais à liberdade, à privacidade e ao livre desenvolvimento da personalidade. Esta regra se aplica às operações realizadas por pessoas físicas ou jurídicas, públicas ou privadas, em suporte físico ou digital. Ela define dois

principais atores no tratamento de dados: o Controlador de Dados, responsável pelas decisões, e o Operador, que realiza o tratamento, bem como o Encarregado da Proteção de Dados, que assegura a ligação entre os titulares dos dados e a Autoridade Nacional de Proteção de Dados (ANPD). A LGPD exige que a finalidade do uso dos dados seja clara e comunicada ao titular, principalmente quando se tratar de políticas públicas. O compartilhamento de dados entre órgãos públicos é permitido sem consentimento, sujeito à transparência e justificativa vinculada a políticas públicas específicas. A lei também garante aos interessados uma série de direitos e estabelece mecanismos de transparência e segurança que devem ser respeitados por toda a administração pública (BRASIL, 2018).

1.3 OBJETIVOS DA PESQUISA

O objetivo geral desta tese é desenvolver e aplicar metodologias que possam auxiliar na formulação de políticas públicas voltadas à mitigação dos impactos da COVID-19 e à preparação do estado de Minas Gerais para futuras pandemias.

Os objetivos específicos incluem:

1. Identificar quais características socioeconômicas da população mineira estão relacionadas a uma maior vulnerabilidade à COVID-19.
2. Desenvolver ou adaptar metodologias que permitam classificar os municípios mineiros quanto ao seu risco de transmissão da COVID-19 e de outras doenças virais.
3. Aplicar análises estatísticas espaciais e modelagem multicritério para compreender padrões de disseminação da doença e subsidiar estratégias de mitigação de riscos.

1.4 METODOLOGIAS APLICADAS E DESENVOLVIDAS

Esta seção descreve em detalhe os procedimentos metodológicos desenvolvidos e aplicados ao longo desta tese de doutorado, organizada em quatro eixos analíticos distintos e complementares. Cada subseção aborda uma metodologia específica, destacando a área de estudo, a escala de análise, as etapas do processo, os dados utilizados e as ferramentas aplicadas, bem como adaptações ou inovações implementadas no escopo da pesquisa.

1.4.1 Análise Bibliométrica Comparativa

Área de Estudo e Escala: Foram considerados três recortes geográficos: global, nacional (Brasil) e regional (Minas Gerais), abrangendo o período de 2020 a janeiro de 2025. Essa divisão permitiu comparar a produção científica em diferentes escalas e identificar lacunas regionais de pesquisa.

O objetivo desse capítulo foi mapear e comparar a produção científica relacionada à COVID-19 e aos fatores socioeconômicos, destacando tendências, redes de colaboração, temáticas predominantes e o papel de instituições e países na produção de conhecimento. Para tal, foram utilizadas as bases bibliográficas Scopus e Web of Science, assim como os pacotes pubmedR e bibliometrix no software R.

As etapas metodológicas percorridas para elaboração deste capítulo englobam o delineamento do escopo analítico da análise bibliométrica, a definição dos critérios de busca nas bases de dados científicas internacionais, a extração e padronização dos registros bibliográficos, bem como a aplicação de técnicas quantitativas para identificação de padrões de produção científica, redes de colaboração, palavras-chave recorrentes e tendências temáticas. O processo também incluiu comparações entre os recortes geográficos (global, nacional e regional), permitindo uma análise crítica da distribuição espacial do conhecimento científico sobre os impactos socioeconômicos da COVID-19. A metodologia pode ser sintetizada da seguinte maneira:

1. Definição de palavras-chave estratégicas ("COVID-19" OR "SARS-CoV-2" AND "socioeconomic") e aplicação de filtros para coleta de dados no contexto do Brasil e de Minas Gerais.
2. Coleta de dados nas plataformas Scopus e Web of Science.
3. Processamento dos dados com o pacote pubmedR, realizando limpeza (remoção de duplicatas), organização e padronização dos metadados.
4. Análise com o pacote bibliometrix, com foco em indicadores como volume anual de publicações, autores e instituições mais produtivas, redes de coautoria, palavras-chave e colaboração internacional.
5. Construção de visualizações como mapas de calor, redes e gráficos de tendência.

Procedimentos Desenvolvidos (descrição das soluções metodológicas específicas elaboradas ao longo da pesquisa):

- Adaptação do fluxo de coleta: a estratégia de busca foi ajustada de forma a permitir a segmentação dos dados bibliográficos por recortes geográficos (global, nacional e regional), utilizando diferentes combinações de palavras-chave e filtros específicos em cada base de dados. Essa adaptação garantiu a coleta diferenciada dos artigos relevantes para cada escala de análise.
- Desenvolvimento de quadros comparativos: foram elaborados painéis e tabelas que sintetizam os principais indicadores bibliométricos (como volume de publicações, taxa de crescimento, número médio de autores por artigo, palavras-chave mais frequentes e colaboração internacional) em cada nível geográfico, permitindo uma comparação direta e estruturada entre as escalas analisadas.
- Interpretação contextualizada dos resultados: os achados da análise foram interpretados à luz das desigualdades regionais em infraestrutura de pesquisa, políticas de fomento à ciência e capacidades institucionais. Essa abordagem permitiu uma leitura crítica dos dados, evidenciando disparidades na produção científica e destacando oportunidades de fortalecimento da pesquisa em contextos locais.

1.4.2 Modelagem Estatística Espacial: Autocorrelação e Regressões

Dois estudos foram desenvolvidos com base na metodologia descrita nesta seção, tendo como área de abrangência os 853 municípios do estado de Minas Gerais, o que possibilitou uma análise abrangente e detalhada do território estadual. No primeiro estudo, a metodologia foi aplicada em escala espacial, no nível municipal, com recorte temporal acumulado entre março e outubro de 2020, correspondente à fase inicial da pandemia de COVID-19 no estado. No segundo estudo, foram analisados três períodos críticos da pandemia — julho de 2020, abril de 2021 e fevereiro de 2022 —, adotando-se uma abordagem espaço-temporal. A escala de análise permaneceu municipal, e os recortes temporais representaram as principais ondas de disseminação da COVID-19 em Minas Gerais. O objetivo central foi avaliar as mudanças nos determinantes socioeconômicos da propagação da doença ao longo do tempo, considerando a dinâmica espaço-temporal da pandemia. Essa abordagem permitiu compreender como variáveis estruturais e contextuais influenciaram a evolução da COVID-19 no estado. A etapa foi fundamental para a identificação de padrões espaciais de disseminação do vírus e para a análise

da associação entre características socioeconômicas municipais e indicadores epidemiológicos (casos e óbitos), por meio de modelos analíticos que incorporam a estrutura espacial dos dados.

As fontes de dados utilizadas nestas etapas da pesquisa incluíram registros oficiais da Secretaria de Estado da Saúde de Minas Gerais (SES-MG), os quais forneceram informações detalhadas sobre os casos confirmados e óbitos por COVID-19 nos municípios mineiros. Esses dados epidemiológicos foram essenciais para a construção dos indicadores de disseminação e impacto da pandemia. Complementarmente, foram incorporados indicadores socioeconômicos provenientes do Instituto de Pesquisa Econômica Aplicada (IPEA) e da Fundação João Pinheiro (FJP), os quais forneceram variáveis explicativas relacionadas à infraestrutura urbana, condições de saúde, longevidade, renda e educação, permitindo uma análise mais ampla dos fatores associados à propagação da doença (COSTA; MARGUTI, 2015; FJP, 2019b; PINTO; COSTA; MARQUES, 2013; SES-MG, 2025b).

A modelagem estatística incorporou a estimação de diferentes modelos espaciais para cada um dos períodos: modelo de regressão linear clássica (OLS), modelo de erro espacial (SEM), modelo de defasagem espacial (SAR) e modelo espacial autoregressivo com média móvel (SARMA). Essa abordagem multivariada possibilitou avaliar o impacto direto e indireto das variáveis socioeconômicas na incidência da COVID-19 em diferentes momentos da pandemia. Foram estimados os efeitos de retroalimentação espacial (*spillover effects*) e comparados os coeficientes dos modelos entre os três períodos, permitindo identificar transformações nos perfis de vulnerabilidade municipal ao longo do tempo.

As etapas metodológicas desta fase da pesquisa envolveram, primeiramente, a elaboração de uma base integrada composta por indicadores epidemiológicos (casos e óbitos) e variáveis socioeconômicas municipais. Em seguida, foi realizada uma análise exploratória dos dados, incluindo a construção de mapas temáticos que possibilitaram uma visualização inicial da distribuição espacial das variáveis. A modelagem estatística teve início com a aplicação de regressões lineares múltiplas pelo método Stepwise, com o objetivo de identificar os melhores preditores para os desfechos epidemiológicos. Posteriormente, foram aplicados testes de autocorrelação espacial, tanto global (Moran's I) quanto local (LISA), para verificar a existência de dependência espacial nos dados. Diante da confirmação dessa dependência, utilizou-se o teste multiplicador de Lagrange para determinar o modelo espacial mais adequado. Com base nos resultados obtidos, foram estimados modelos espaciais do tipo SEM, SAR e SARMA, seguidos por uma comparação sistemática dos ajustes dos modelos com base em estatísticas como o AIC, o log-likelihood e o coeficiente de determinação ajustado (R^2). Além disso, utilizou-se o teste espacial de *Hausman* para validar os modelos SEM e aplicou-se uma

simulação de impactos via estimativa Bayesiana (MCMC) para os modelos SAR e SARMA, com o intuito de avaliar os efeitos diretos e indiretos das variáveis sobre a disseminação da COVID-19 (ANSELIN, 1988, 1995; ANSELIN et al., 1996; ANSELIN; REY, 1991; ANSELIN; SYABRI; KHO, 2010; ASTAIZA-GÓMEZ, 2020; BREUSCH; PAGAN, 1980; KELLEY PACE; LESAGE, 2008; LESAGE; PACE, 2009).

As etapas analíticas foram conduzidas no ambiente estatístico R, utilizando os pacotes *MASS*, *car*, *spdep*, *spatialreg*, *sf* e *ggplot2*, que permitiram desde a construção das matrizes de vizinhança até a estimação dos modelos espaciais e a simulação dos impactos. Os scripts com as metodologias executadas podem ser encontrados por meio dos links a seguir: <https://doi.org/10.5281/zenodo.15236522> (modelo OLS com seleção de variáveis via *stepwise*) e <https://doi.org/10.5281/zenodo.15236344> (modelos espaciais). Entre os procedimentos metodológicos desenvolvidos, destaca-se a construção de uma matriz de vizinhança do tipo contiguidade de primeira ordem (Queen's case), fundamental para a estruturação dos modelos espaciais. Além disso, os modelos estimados foram validados por meio da análise de resíduos e de testes de robustez, como os testes de Lagrange Multiplicador (LM e LM robust), garantindo a consistência e a adequação estatística das inferências realizadas (ANSELIN, 1988; ASTAIZA-GÓMEZ, 2020; BIVAND et al., 2024, 2025; PEBESMA et al., 2024).

O pacote *sf* foi empregado para a manipulação de dados geográficos e a transformação de sistemas de coordenadas, enquanto o *spdep* permitiu a construção das matrizes de vizinhança e a realização de testes estatísticos espaciais, como o Moran's I. Para a estimação dos modelos SAR, SEM e SARMA utilizou-se o *spatialreg*, uma das ferramentas mais robustas para ajuste de modelos espaciais autoregressivos e de erro espacial (BIVAND et al., 2024, 2025; PEBESMA et al., 2024). O pacote *car* foi utilizado para diagnósticos e testes em modelos de regressão, incluindo regressão linear (OLS), ele oferece diversas funções úteis para verificação de pressupostos, detecção de multicolinearidade, análise de resíduos e identificação de pontos influentes (FOX et al., 2024). O pacote *MASS* foi utilizado para a seleção de variáveis com base no critério de informação de Akaike (AIC), garantindo a escolha do modelo mais simples e estatisticamente adequado (RIPLEY et al., 2025). Para visualização dos resultados, o *ggplot2* foi empregado na construção de mapas temáticos e gráficos de dispersão espacial, permitindo a interpretação intuitiva dos padrões espaciais da COVID-19 (WICKHAM et al., 2024).

1.4.3 Construção do Índice de Vulnerabilidade à Transmissibilidade do SARS-CoV-2 (IVT_{SARS-CoV-2})

Esta etapa da pesquisa abrangeu todos os municípios do estado de Minas Gerais, com enfoque espacial em nível municipal e recorte temporal limitado aos casos acumulados durante o mês de fevereiro de 2022. O objetivo central foi desenvolver um índice sintético capaz de representar, de forma integrada, a vulnerabilidade dos municípios mineiros à transmissão da COVID-19, considerando aspectos estruturais, epidemiológicos e sociais que influenciam a disseminação da doença.

As fontes de dados utilizadas incluíram informações epidemiológicas provenientes da Secretaria de Estado da Saúde de Minas Gerais (SES-MG), com dados sobre a incidência da COVID-19, além de indicadores socioeconômicos obtidos junto à Fundação João Pinheiro (FJP), abrangendo variáveis como renda, escolaridade, acesso à saúde e infraestrutura urbana. Complementarmente, dados urbanos foram extraídos da coleção 7.0 do MapBiomas, a partir da qual se obteve a delimitação das áreas urbanas dos municípios. Adicionalmente, os dados de corredores urbanos foram estimados com base em informações vetoriais obtidas do OpenStreetMap (OSM), sendo ambos os tratamentos geoespaciais realizados por meio do software QGIS. Esses dados contribuíram de forma decisiva para a caracterização morfológica e funcional dos municípios, permitindo maior robustez na análise espacial da vulnerabilidade.

As etapas metodológicas seguiram uma sequência estruturada. Primeiramente, foi realizada a seleção das variáveis explicativas a partir da revisão da literatura e com base na correlação estatística com a variável dependente — os casos acumulados de COVID-19. As variáveis selecionadas foram submetidas à padronização estatística, assegurando a comparabilidade entre diferentes escalas de medida. Em seguida, aplicou-se a técnica de Análise de Decisão Multicritério (ADMC), com pesos atribuídos proporcionalmente à força de correlação entre cada variável e os casos acumulados. Com base nesses pesos, foi calculado o Índice de Vulnerabilidade à Transmissão do SARS-CoV-2 (IVT_{SARS-CoV-2}), permitindo a classificação dos municípios em diferentes faixas de risco. A etapa final consistiu na validação cruzada por meio da técnica *k folds* por meio do pacote *scikit-learn* em ambiente Python. No código executável, foram inseridos os coeficientes do modelo e as notas atribuídas às variáveis independentes, tratadas diretamente como variáveis do modelo. Para a variável dependente, utilizou-se o resultado da classificação de vulnerabilidade calculado para cada município.

Do ponto de vista metodológico, a construção do índice exigiu uma integração cuidadosa entre dados quantitativos e procedimentos de geoprocessamento. A utilização da

coleção 7.0 do MapBiomas permitiu a identificação precisa das áreas urbanizadas dos municípios, enquanto os dados do OpenStreetMap foram processados para estimar a densidade e a conectividade dos corredores urbanos. Esses dois componentes foram fundamentais para capturar elementos da morfologia urbana que, segundo a literatura, afetam diretamente o potencial de transmissão viral (CHEN et al., 2024; DAVID et al., 2013; KNOWLES, 2012; KWOK et al., 2021; LI; YANG, 2003; MARCONATO; PARRÉ; COELHO, 2021; MINGHINI; SARRETTA; NAPOLITANO, 2022; MOONEY et al., 2021; YU et al., 2021). A abordagem multicritério adotada assegurou que cada variável contribuísse de forma proporcional à sua relevância estatística, sem sobreposição ou redundância. Essa metodologia buscou equilibrar objetividade analítica com sensibilidade contextual, resultando em um indicador robusto, replicável e sensível às desigualdades territoriais em saúde pública.

A operacionalização dessas etapas envolveu o uso de diferentes ferramentas. O QGIS foi utilizado para o processamento espacial e georreferenciamento das variáveis; o Excel/LibreOffice foi empregado para o cálculo dos pesos e consolidação dos dados; e o ambiente R contribuiu com análises estatísticas complementares. Entre os procedimentos desenvolvidos, destaca-se a automatização do cálculo dos pesos a partir da matriz de correlação, o que conferiu maior agilidade e padronização ao processo.

O processo de espacialização das variáveis foi conduzido no ambiente QGIS, com ênfase na etapa de rasterização. A variável vetorial correspondente aos corredores foi convertida em raster com pixels de 10 metros de lado, permitindo o cálculo da área ocupada por corredores em cada município. Para isso, contabilizou-se o número de pixels representando corredores dentro dos limites municipais e, em seguida, multiplicou-se esse valor pela área de cada pixel, obtendo-se assim a área total de corredores em escala municipal. O mesmo procedimento foi adotado para a variável referente à área urbana. As demais variáveis também foram rasterizadas, viabilizando a aplicação da álgebra de mapas. Para a operacionalização do índice no ambiente DINAMICA EGO, foi necessária a realização de uma transformação linear prévia, a fim de converter os valores originais — representados por decimais — em números inteiros, condição essencial para o processamento raster posterior.

Para a composição do índice sintético, foi adotada uma abordagem empírica de atribuição de pesos com base nos coeficientes de correlação de Pearson entre cada variável explicativa e a variável de referência (casos de COVID-19 do mês de fevereiro de 2022), associada ao fenômeno investigado. Essa estratégia visa captar a força da associação linear entre cada variável e o critério de interesse, assumindo que variáveis mais fortemente correlacionadas possuem maior relevância explicativa no contexto do estudo. Inicialmente, os

coeficientes de correlação de Pearson foram calculados individualmente para as nove variáveis selecionadas. Em seguida, foi realizada a soma dos valores absolutos desses coeficientes, de modo a considerar a intensidade da relação, independentemente do sentido (positivo ou negativo). A contribuição relativa de cada variável foi então expressa como o percentual de seu coeficiente em relação ao total somado. Esses percentuais foram convertidos para uma escala entre 0 e 1, dividindo-se os valores por 100. O resultado desse processo gerou um vetor de pesos cuja soma totaliza 1, assegurando a proporcionalidade entre as variáveis na etapa de agregação do índice.

A escolha por essa metodologia se justifica por sua simplicidade, reprodutibilidade e fundamentação empírica. Diferentemente da atribuição de pesos arbitrários, essa técnica incorpora a estrutura real dos dados ao processo decisório, respeitando a variabilidade observada entre os municípios. Ademais, ao não depender de técnicas mais complexas como a Análise de Componentes Principais (PCA), a abordagem preserva a interpretabilidade individual de cada variável no índice final, facilitando a análise e a comunicação dos resultados. Tal estratégia é especialmente adequada em contextos nos quais há uma variável ou indicador de referência bem definido, servindo como base para avaliar a importância relativa das variáveis explicativas.

Após a definição dos pesos, cada variável padronizada foi submetida a um processo de estratificação por classes, sendo convertida em uma escala ordinal de pontuação de 0 a 10. Essa transformação visou permitir a agregação homogênea das variáveis na composição do índice sintético. Os municípios com os maiores valores padronizados em variáveis associadas ao risco (como, por exemplo, a maior proporção de empregos no setor de serviços) foram alocados nas classes superiores e atribuídos com a nota máxima (10), enquanto aqueles sem trabalhadores nesse ramo econômico foram classificados na faixa inferior, recebendo a nota mínima (0).

O índice final, proposto para cada município, variou entre 0 e 10, onde 0 representava uma pontuação nula em todas as variáveis e 10 indicava pontuação máxima (nota 10) em todas as variáveis. Essa padronização permite a comparação direta da vulnerabilidade à transmissibilidade da COVID-19 entre os municípios analisados. O índice de vulnerabilidade à transmissibilidade do SARS-CoV-2 ($IVT_{SARS-CoV-2}$) pode ser calculado por meio da aplicação do modelo de análise multicritério, cuja formulação genérica é expressa pela seguinte equação:

$$IVT_{SARS-CoV-2} = \sum_{i=1}^n (p_i \times x_i) \quad 1$$

Onde:

- p_i representa o peso atribuído à variável i ;
- x_i é a nota da variável i no âmbito municipal;
- n é o número total de variáveis considerados.

Por meio do método de validação cruzada, o conjunto de dados é particionado em k *folds*. O modelo é treinado em $k-1$ *folds* e avaliado no *fold* restante. Esse processo é repetido k vezes, de modo que cada *fold* seja utilizado como conjunto de teste uma vez. A performance do modelo, medida pelo Erro Quadrático Médio (EQM), é calculada em cada iteração. A média desses valores fornece uma estimativa robusta do desempenho do modelo em dados não vistos. A validação cruzada é fundamental para evitar o sobreajuste, um problema que ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar (ARLOT; CELISSE, 2010; BISHOP; NASRABADI, 2006; BROWNE, 2000; PEDREGOSA et al., 2011).

Esse procedimento metodológico possibilitou o cálculo do índice final por meio da álgebra de mapas, considerando os pesos atribuídos a cada camada raster correspondente às variáveis previamente padronizadas. Como resultado, obteve-se um mapa contínuo de vulnerabilidade, o qual foi posteriormente agregado à escala municipal, permitindo a categorização dos territórios em diferentes níveis de risco.

1.5 PRODUTOS DA TESE DE DOUTORADO


A presente tese resultou na produção de quatro eixos analíticos complementares, que, em conjunto, ampliam a compreensão sobre a relação entre a COVID-19 e os fatores socioeconômicos em escala municipal no estado de Minas Gerais (FIGURA 1.1):

- (i) Uma revisão bibliométrica da literatura científica sobre a pandemia e seus determinantes socioeconômicos;
- (ii) A investigação da autocorrelação espacial entre casos/mortes por COVID-19 e indicadores municipais;
- (iii) A construção de um índice de vulnerabilidade municipal à transmissão do SARS-CoV-2;
- (iv) Uma análise espaço-temporal da pandemia em três períodos críticos, com ampliação da modelagem espacial.

O primeiro eixo mapeou a produção científica internacional relacionada à COVID-19 e variáveis socioeconômicas, oferecendo uma base conceitual robusta para os demais produtos da tese. O segundo eixo evidenciou a presença de padrões espaciais na distribuição dos casos e óbitos no estado, destacando a influência das desigualdades territoriais. O terceiro eixo resultou na formulação de um índice de vulnerabilidade à transmissão do SARS-CoV-2, sintetizando múltiplas variáveis socioeconômicas e de infraestrutura municipal. Por fim, o quarto eixo incorporou uma abordagem espaço-temporal ao modelo de regressão espacial, permitindo analisar a evolução dos determinantes da COVID-19 ao longo de três ondas da pandemia.

Esses produtos integram diferentes dimensões de análise — teórica, espacial, estatística e aplicada — e proporcionam subsídios relevantes para o enfrentamento de pandemias em contextos marcados por desigualdades regionais. Além disso, contribuem para o planejamento de políticas públicas mais eficazes, baseadas na realidade específica de cada território.

Figura 1.1 – Fluxograma com sequência metodológica aplicada na tese



1.6 ESTRUTURA DA TESE

A presente tese está estruturada em formato de compilação de artigos científicos. Inicialmente, apresenta-se a introdução, seguida da revisão bibliográfica, dos objetivos do estudo e da descrição da sequência metodológica adotada ao longo da pesquisa. Na sequência, são apresentados os Artigos 1, 2, 3 e 4, elaborados durante o período de doutoramento. Por fim, apresenta-se a conclusão geral da tese, na qual os principais achados são discutidos de forma integrada, à luz dos objetivos propostos. A estrutura da tese pode ser visualizada a seguir.

1 INTRODUÇÃO GERAL - Apresentação do contexto da pesquisa, justificativa, objetivos, metodologia e estrutura da tese.

2 FATORES SOCIOECONÔMICOS E COVID-19: UMA ANÁLISE BIBLIOMÉTRICA - Revisão sistemática da literatura sobre a relação entre características socioeconômicas e vulnerabilidade à COVID-19, identificando lacunas e tendências.

3 WHAT ROLE DO SOCIAL VARIABLES AND HEALTH PLAY IN THE SPREAD OF COVID-19 IN THE STATE OF MINAS GERAIS – BRAZIL? - Investigação empírica da disseminação da COVID-19 no estado por meio de análises estatísticas espaciais.

4 $IVT_{SARS-COV-2}$: UM ÍNDICE MULTICRITÉRIO E A DINÂMICA URBANA EM MINAS GERAIS, BRASIL - Desenvolvimento de um índice de vulnerabilidade municipal à COVID-19. viral.

5 MODELAGEM ESPACIAL DA DISSEMINAÇÃO DA COVID-19 EM MINAS GERAIS: ANÁLISE DAS TRÊS PRIMEIRAS ONDAS E FATORES SOCIOECONÔMICOS - Aprofundamento da investigação empírica da disseminação da COVID-19 no estado por meio de análises de novas estatísticas espaciais e diferentes recortes temporais.

6 CONCLUSÃO GERAL - Síntese dos principais achados e implicações para políticas públicas e pesquisas futuras.

2 FATORES SOCIOECONÔMICOS E COVID-19: UMA ANÁLISE BIBLIOMÉTRICA¹

Resumo

A pandemia da COVID-19 gerou impactos socioeconômicos significativos globalmente, evidenciando desigualdades estruturais e transformando o panorama da pesquisa acadêmica. Este estudo realiza uma revisão bibliométrica comparativa para analisar a produção científica sobre os impactos socioeconômicos da COVID-19 em três níveis geográficos: global, nacional (Brasil) e regional (Minas Gerais). Para tanto, os dados foram coletados nas bases de dados Scopus e Web of Science, utilizando critérios de busca específicos, e analisados utilizando os pacotes pubmedR e bibliometrix no ambiente R. Os resultados indicam que a produção científica sobre o tema atingiu o pico nos primeiros anos da pandemia, com posterior declínio na taxa de crescimento global (-38,77%) e nacional (-55,91%). No entanto, em Minas Gerais, observou-se um aumento de 41,42%, indicando um crescimento recente do interesse por estudos regionais. A análise das redes de colaboração internacional revelou a centralidade de países como Estados Unidos, Reino Unido, China, Espanha e Canadá na produção científica e na disseminação do conhecimento. Além disso, os dados mostram uma predominância de pesquisas focadas nos efeitos da pandemia sobre grupos vulneráveis, mercado de trabalho, pobreza e saúde mental. Os resultados destacam a necessidade de investir mais em pesquisas em contextos locais, particularmente em países em desenvolvimento, e reforçam a importância da cooperação científica internacional. Este estudo contribui para a compreensão da dinâmica da produção acadêmica sobre a COVID-19 e seus impactos socioeconômicos, fornecendo insights para pesquisas futuras e para o desenvolvimento de políticas públicas baseadas em evidências.

Palavras-chave: COVID-19, impactos socioeconômicos, bibliometria, desigualdades sociais, análise comparativa.

¹ Artigo de autoria de Matheus Luiz Jorge Cortez e Úrsula Ruchkys de Azevedo em preparação para submissão.

2.1 INTRODUÇÃO

A pandemia da COVID-19 impactou de forma abrangente a sociedade global, transcendendo o campo da saúde pública para revelar e amplificar desigualdades socioeconômicas preexistentes em diferentes escalas. Desde o seu início, em 2020, a disseminação do vírus do SARS-CoV-2 e as medidas de contenção adotadas, como lockdowns e restrições de mobilidade, expuseram vulnerabilidades estruturais que afetam de maneira desproporcional populações socioeconomicamente desfavorecidas (BAMBRA et al., 2020; PATEL et al., 2020). Em países de baixa e média renda, os efeitos da pandemia foram particularmente severos, intensificando dificuldades no acesso a serviços essenciais, como saúde, educação e trabalho formal (AHMED et al., 2020; BONACCORSI et al., 2020).

As disparidades socioeconômicas manifestaram-se em taxas mais elevadas de infecção e mortalidade por COVID-19 em comunidades com menor renda e alta densidade populacional, resultado de condições habitacionais inadequadas, maior exposição ocupacional e acesso limitado a medidas de proteção, incluindo distanciamento social e equipamentos de proteção individual (BAENA-DÍEZ et al., 2020; MENA et al., 2021). Fatores como o nível educacional e a inserção no mercado de trabalho formal, desempenharam um papel crítico na vulnerabilidade à doença e na capacidade de recuperação econômica no período pós-pandemia (BORJAS, 2020).

Além dos impactos diretos na saúde, a crise sanitária agravou a precarização do trabalho, afetando desproporcionalmente trabalhadores informais e grupos marginalizados, o que resultou em aumento do desemprego e da insegurança alimentar, especialmente em países em desenvolvimento (FAO, 2021). Embora medidas governamentais, como auxílios emergenciais e programas de transferência de renda, tenham sido implementados para mitigar esses efeitos, sua eficácia variou significativamente, refletindo as diferentes capacidades institucionais e os recursos disponíveis em cada contexto nacional (GENTILINI, 2020).

Diante da complexidade desses impactos, torna-se essencial compreender como a produção científica tem abordado as interseções entre a pandemia e as desigualdades socioeconômicas. A análise bibliométrica destaca-se como uma ferramenta metodológica robusta para mapear padrões de produção científica, identificar autores e instituições de destaque, analisar redes de colaboração e explorar tendências temáticas ao longo do tempo. Esse tipo de análise é particularmente relevante para captar a evolução das pesquisas sobre COVID-19 em diferentes contextos geográficos e socioeconômicos, além de fornecer subsídios

para o desenvolvimento de políticas públicas mais informadas e eficazes (MACCARO et al., 2023; NICOLA et al., 2020).

Nesse estudo realiza-se uma revisão bibliométrica comparativa sobre a produção científica sobre os impactos socioeconômicos da COVID-19 em três níveis: global, nacional (Brasil) e regional (Minas Gerais). A análise baseia-se em artigos científicos indexados nas bases Scopus e Web of Science, utilizando as palavras-chave "COVID-19" OR "SARS-CoV-2" AND "Socioeconomic", com refinamentos para contemplar as diferentes escalas geográficas. Os dados foram processados com o pacote pubmedR, e a análise conduzida com o bibliometrix, visando identificar tendências emergentes, lacunas na literatura e potenciais áreas para futuras pesquisas.

Ao examinar a evolução da produção científica sobre os efeitos socioeconômicos da pandemia, este artigo busca contribuir para uma compreensão mais ampla das desigualdades estruturais evidenciadas pela crise sanitária e das estratégias adotadas para sua mitigação em diferentes contextos. Assim, espera-se oferecer insights relevantes para o aprimoramento de políticas públicas e para o fortalecimento da resiliência socioeconômica diante de futuras crises globais.

2.2 MÉTODOS

2.2.1 Abordagem geral

Este estudo adota uma abordagem bibliométrica comparativa para examinar a produção científica relacionada aos impactos socioeconômicos da COVID-19 em três diferentes níveis geográficos: global, nacional (Brasil) e regional (Minas Gerais). A análise bibliométrica permite identificar padrões de produção acadêmica, principais autores, instituições de destaque, redes de colaboração e tendências temáticas ao longo do tempo, oferecendo uma visão abrangente da evolução do conhecimento sobre o tema.

2.2.2 Coleta de dados

A coleta de dados foi realizada nas bases de dados Scopus e Web of Science, reconhecidas internacionalmente por sua abrangência e relevância científica. Utilizaram-se as seguintes palavras-chave para a busca dos artigos:

- Global: “COVID-19” OR “SARS-CoV-2” AND “Socioeconomic”;

- Nacional (Brasil): “COVID-19” OR “SARS-CoV-2” AND “Socioeconomic” AND (“Brazil” OR “Brasil”);
- Regional (Minas Gerais): “COVID-19” OR “SARS-CoV-2” AND “Socioeconomic” AND “Minas Gerais”.

Foram incluídos artigos publicados a partir de 2020, considerando apenas artigos originais e revisões sistemáticas. Documentos duplicados, editoriais, cartas ao editor e resumos de conferências foram excluídos para garantir a qualidade e a relevância do corpus analisado.

2.2.3 Processamento e análise de dados

Os dados extraídos foram organizados e processados utilizando o pacote pubmedR no ambiente R, o que permitiu a padronização e filtragem dos registros. A análise bibliométrica foi conduzida com o pacote bibliometrix, que possibilitou a obtenção de diversos indicadores, incluindo:

- Evolução temporal das publicações;
- Principais periódicos e instituições acadêmicas;
- Países mais produtivos e suas redes de colaboração;
- Termos e palavras-chave mais recorrentes e suas co-ocorrências;

Para mapear dinâmica das áreas de pesquisa ao longo do tempo, aplicou-se uma análise de tendências temáticas, permitindo a identificação de novas abordagens e lacunas na literatura.

2.2.4 Comparação entre diferentes níveis geográficos

A comparação entre os níveis global, nacional e regional foi realizada por meio de análise descritiva dos principais indicadores bibliométricos, com o objetivo de identificar semelhanças e diferenças na produção acadêmica. Essa abordagem visa compreender as particularidades dos impactos socioeconômicos da COVID-19 em cada contexto geográfico e avaliar como a pesquisa está estruturada globalmente, no Brasil e em Minas Gerais.

2.2.5 Limitações do estudo

Embora as bases de dados Scopus e Web of Science, ofereçam uma ampla cobertura, a inclusão de outras fontes, como o Google Scholar e repositórios institucionais, poderia ampliar o escopo da análise. Além disso, a interpretação dos resultados está condicionada à

disponibilidade de artigos indexados nessas bases de dados e às metodologias aplicadas nos estudos analisados, o que pode introduzir vieses na análise comparativa.

Essa metodologia busca fornecer uma compreensão aprofundada e comparativa da literatura científica sobre os impactos socioeconômicos da pandemia, contribuindo para pesquisas futuras e subsidiando a formulação de políticas públicas mais eficazes e baseadas em evidências.

2.3 RESULTADOS E DISCUSSÕES

2.3.1 Principais resultados

Os principais resultados encontrados na análise bibliométrica das publicações sobre os impactos socioeconômicos da COVID-19 nas esferas global, nacional (Brasil) e regional (Minas Gerais) são apresentados na Tabela 2.1, com base em indicadores relevantes.

Tabela 2.1 – Principais resultados da análise bibliométrica nas esferas de estudo

Descrição		Resultados		
		Global	Brasil	Minas Gerais
Principais informações sobre os dados	Período	2020:2025	2020:2025	2020:2024
	Fontes (revistas, livros, etc.)	3649	246	12
	Documentos	9960	446	13
	Taxa de crescimento anual (%)	-38,77	-55,91	41,42
	Idade média do documento	2,80	2,93	2,77
	Média de citações por documento	16,81	15,07	13,92
	Palavras-chave plus	12375	2007	105
	Palavras-chave do autor	16692	1000	50
Autores e colaborações	Autores	49748	2818	103
	Autores de documentos de autoria única	614	9	0
	Documentos de autoria única	655	9	0
	Coautores por documento	6,92	8,14	8,08
	Coautorias internacionais (%)	19,61	4,04	7,69
Tipos de documentos	Artigo	9716	446	13
	Artigo; artigo de dados	19	-	-
	Artigo; acesso antecipado	217	-	-
	Artigo; artigo de procedimentos	6	-	-
	Artigo; publicação retratada	2	-	-

A análise abrange publicações entre 2020 e 2025 para os níveis global e nacional, enquanto para Minas Gerais, o período é limitado até 2024, devido à ausência de registros em

2025 até o momento da coleta de dados. Observa-se um menor volume de publicações na esfera regional, refletindo um cenário de pesquisa mais restrito.

Foram identificados 9.960 documentos em âmbito global, 446 relacionados ao Brasil e, apenas 13 focados em Minas Gerais. O volume expressivo de publicações em níveis global e nacional evidencia o interesse acadêmico pelo tema, enquanto a baixa produção em Minas Gerais pode estar associada à menor densidade pesquisadores e investimentos específicos para essa temática.

A taxa de crescimento anual foi negativa para o contexto global (-38,77%) e nacional (-55,91%), indicando uma redução do interesse acadêmico à medida que a pandemia deixou de ser uma emergência sanitária imediata. Em contraste, Minas Gerais apresentou uma taxa positiva (41,42%), sugerindo um interesse crescente em estudos regionais, possivelmente impulsionado por análises tardias ou investigações sobre impacto de longo prazo.

O número de fontes acadêmicas variou de 3.649 em escala global, para 246 no Brasil e apenas 12 em Minas Gerais. Essa discrepância reflete a concentração da produção científica em contextos mais amplos e a limitação de fontes para análises em escalas menores.

Em escala global e nacional a produção científica é vasta e diversificada, abrangendo um grande número de fontes e artigos publicados. No entanto, a queda na taxa de crescimento anual sugere um esgotamento do interesse inicial pela pandemia. Na escala regional a baixa quantidade de documentos reflete uma limitação na pesquisa em nível estadual. Ademais, a taxa de crescimento positiva sugere que ainda há um aumento no interesse por estudos locais, que podem estar sendo impulsionados por políticas públicas ou iniciativas acadêmicas mais recentes.


Os dados indicam que, enquanto o tema COVID-19 começa a perder relevância na esfera global e nacional, ainda há espaço para investigações aprofundadas em contextos regionais como Minas Gerais. Isso destaca a importância de políticas de incentivo à pesquisa local para garantir que os impactos socioeconômicos da pandemia sejam adequadamente documentados e compreendidos.

2.3.2 Principais periódicos nos contextos global e nacional

Esta seção apresenta os escopos dos dez periódicos mais influentes em âmbito global e nacional no que tange às publicações sobre as relações entre a COVID-19 e os fatores socioeconômicos, abrangendo temas como saúde pública, epidemiologia, sustentabilidade e desigualdades sociais (Figuras 2.1 e 2.2). A análise dessas diretrizes editoriais permite

identificar as abordagens e prioridades de cada revista, contribuindo para uma melhor tomada de decisão por parte dos pesquisadores.

Figura 2.1 – Principais revistas com publicações sobre as relações entre a COVID-19 e fatores socioeconômicos em âmbito global



Fonte: Elaborado pelos autores.

As revistas com maior número de publicações sobre as relações entre a COVID-19 e os fatores socioeconômicos em âmbito global apresentam os seguintes escopos:

International Journal of Environmental Research and Public Health: Esta revista é uma publicação internacional, revisada por pares e de acesso aberto, que abrange todos os aspectos da saúde ambiental e pública. O escopo inclui, mas não se limita a saúde ocupacional, saúde ambiental, epidemiologia, saúde global, higiene e saúde pública (IJERPH, 2025).

PLOS ONE: É uma revista científica de acesso aberto que publica pesquisas originais em todas as disciplinas da ciência, desde a engenharia até a medicina, contemplando as ciências sociais e humanas relacionadas. O escopo é amplo e inclui ciência básica, clínica, translacional e aplicada. A revista aceita artigos de todas as áreas da ciência e não restringe a publicação com base na disciplina (PLOS ONE, 2025).

Frontiers in Public Health: Esta revista multidisciplinar de acesso aberto cobre áreas como saúde ocupacional, saúde mental e reprodutiva, medicina e política social, epidemiologia,

reabilitação, obesidade, questões familiares e sociais, qualidade de vida e educação e promoção da saúde pública (FRONTIERS, 2025).

BMC Public Health: É uma revista de acesso aberto revisada por pares que considera artigos sobre a epidemiologia de doenças e a compreensão de todos os aspectos da saúde pública. O escopo inclui, mas não se limita a saúde pública, epidemiologia, prevenção de doenças, cuidados de saúde e políticas de saúde (BMCPH, 2025).

Sustainability: Esta revista internacional, revisada por pares e de acesso aberto, foca na sustentabilidade ambiental, cultural, econômica e social dos seres humanos. O escopo inclui estudos sobre sustentabilidade ambiental, desenvolvimento sustentável, economia ecológica e sustentabilidade social (SUSTAINABILITY, 2025).

BMJ Open: Esta revista de acesso aberto publica pesquisas médicas de todas as disciplinas e terapias. O escopo inclui estudos de pesquisa clínica, epidemiológica e de saúde pública, bem como estudos de pesquisa qualitativa e de implementação (BMJ, 2025).

Scientific Reports: É uma revista de acesso aberto que publica pesquisas originais de alta qualidade em todas as áreas das ciências naturais e clínicas. O escopo é amplo e cobre todas as áreas da ciência natural, incluindo biologia, química, física e ciências da Terra (SCIENTIFIC REPORTS, 2025).

JAMA Network Open: Esta revista médica internacional de acesso aberto publica pesquisas originais em todas as áreas da medicina e saúde. O escopo inclui estudos clínicos, epidemiológicos e de saúde pública em uma ampla gama de disciplinas médicas (JAMA, 2025).


Vaccines: É uma revista internacional, revisada por pares e de acesso aberto, que abrange todas as pesquisas relacionadas a vacinas. O escopo inclui desenvolvimento de vacinas, avaliação de eficácia, segurança, vigilância pós-comercialização e políticas de vacinação (VACCINES, 2025).

Journal of Racial and Ethnic Health Disparities: Esta revista publica pesquisas que exploram as disparidades de saúde entre diferentes grupos raciais e étnicos. O escopo inclui estudos sobre determinantes sociais da saúde, acesso a cuidados de saúde, resultados de saúde e intervenções destinadas a reduzir disparidades de saúde (JREHD, 2025).

As revistas científicas listadas abrangem uma ampla gama de áreas do conhecimento, refletindo um escopo interdisciplinar e de relevância global. *International Journal of Environmental Research and Public Health*, *BMC Public Health* e *Frontiers in Public Health* possuem um foco na saúde pública e epidemiologia, abordando temas como prevenção de doenças, políticas de saúde e impactos ambientais na saúde. *PLOS ONE* e *Scientific Reports* são periódicos de escopo mais amplo, aceitando artigos de diversas áreas científicas, com um

foco na transparência e reprodutibilidade das pesquisas. BMJ Open e JAMA Network Open concentram-se em estudos clínicos e epidemiológicos, enfatizando a pesquisa médica e sua aplicação na saúde pública. Já Sustainability direciona sua atenção para a sustentabilidade em diversas dimensões, incluindo ambiental, econômica e social, enquanto Vaccines foca especificamente no desenvolvimento, eficácia e impacto das vacinas. Por fim, Journal of Racial and Ethnic Health Disparities se destaca ao abordar as desigualdades raciais e étnicas na saúde, um tema essencial para a equidade em saúde pública. Essas revistas demonstram a importância da pesquisa científica em diferentes contextos, permitindo a disseminação do conhecimento em áreas fundamentais para o desenvolvimento social, ambiental e médico.

Figura 2.2 – Principais revistas com publicações sobre as relações entre a COVID-19 e fatores socioeconômicos no contexto brasileiro



Fonte: Elaborado pelos autores.

Foram cinco os periódicos exclusivos, quando comparando com os periódicos mais relevantes em âmbito global, dentre os dez mais importantes em âmbito nacional no que tange a publicações sobre as relações entre a COVID-19 e os fatores socioeconômicos. A seguir são apresentados os seus escopos:

Cadernos de Saúde Pública: Esta revista é dedicada à publicação de artigos científicos que focam na produção de conhecimento em Saúde Coletiva. Busca fomentar a reflexão crítica

e o debate sobre temas atuais relacionados a políticas públicas e fatores que impactam as condições de vida e a atenção à saúde das populações (CSP, 2025).

Revista de Saúde Pública: Publica contribuições científicas originais sobre temas relevantes para a área da saúde pública (RSP, 2025).

Ciência & Saúde Coletiva: Esta revista aborda uma ampla gama de temas relacionados à saúde coletiva, incluindo políticas de saúde, epidemiologia, ciências sociais em saúde, planejamento e gestão de sistemas de saúde, entre outros. Busca promover a integração do conhecimento científico com a prática em saúde, incentivando a interdisciplinaridade e a intersetorialidade nas abordagens de saúde pública (CSC, 2025).

Revista Brasileira de Epidemiologia: Focada na disseminação de estudos epidemiológicos, esta revista publica artigos originais que contribuem para o avanço do conhecimento na área, incluindo investigações sobre a distribuição e os determinantes de doenças e agravos à saúde em populações humanas. Também aborda metodologias epidemiológicas e avaliações de intervenções em saúde pública (RBE, 2025).

Public Health: É uma revista internacional que publica artigos originais, revisões e comentários sobre todos os aspectos da saúde pública. O escopo inclui epidemiologia, serviços de saúde, medicina preventiva, saúde ocupacional, saúde ambiental, saúde global e políticas de saúde. A revista busca disseminar pesquisas que possam influenciar a prática e a política de saúde pública em nível global (RSPH, 2025).


Os escopos das cinco revistas analisadas refletem a diversidade e a interdisciplinaridade da pesquisa em saúde pública, abordando desde aspectos epidemiológicos até políticas e gestão em saúde. Cadernos de Saúde Pública e Revista de Saúde Pública possuem um enfoque abrangente, priorizando estudos que investigam os determinantes sociais da saúde, as políticas públicas e a organização dos sistemas de saúde. Ciência & Saúde Coletiva se destaca por sua abordagem multidisciplinar, promovendo o diálogo entre diferentes áreas do conhecimento e incentivando uma visão holística sobre a saúde coletiva. Revista Brasileira de Epidemiologia tem um escopo mais específico, voltado para a disseminação de estudos epidemiológicos e metodologias aplicadas à saúde pública, sendo uma referência para pesquisas baseadas em análise de dados populacionais. Já Public Health, com seu escopo internacional, abrange temas diversos em saúde pública global, trazendo contribuições importantes para a formulação de políticas e práticas baseadas em evidências. Dessa forma, essas revistas desempenham um papel essencial na produção e disseminação do conhecimento científico, contribuindo para a melhoria das condições de saúde das populações e para a implementação de estratégias eficazes no enfrentamento de desafios sanitários.

2.3.3 Análise dos dados no contexto global

2.3.3.1 principais países em termos de produções científicas sobre os impactos socioeconômicos da COVID-19


Os cinco países com o maior número de produções científicas sobre o tema são os Estados Unidos (11.665), o Reino Unido (3.082), a China (2.673), o Brasil (2.117) e o Canadá (1.765) (Figura 2.3). No entanto, ao analisar a nacionalidade dos autores correspondentes, observa-se uma variação na classificação dos países, sendo os Estados Unidos (2.503) o líder, seguidos pela China (626), o Reino Unido (621), o Brasil (514) e a Espanha (352) (Figura 2.4). Essa diferença sugere que a produção científica nacional nem sempre reflete exclusivamente as pesquisas desenvolvidas por pesquisadores locais.

Figura 2.3 – Espacialização da produção científica por país



Fonte: Elaborado pelos autores.

Figura 2.4 – Espacialização das produções científicas por nacionalidade dos autores correspondentes



Fonte: Elaborado pelos autores.


A divergência entre o volume de publicações de um país e a nacionalidade dos autores correspondentes pode indicar que, embora determinada nação apresente alta produção científica sobre o tema, os artigos publicados nem sempre tratam diretamente da realidade desse país. Esse fenômeno pode estar relacionado à mobilidade acadêmica, com pesquisadores estrangeiros radicados em países com maior infraestrutura científica publicando estudos sobre seus países de origem ou regiões de interesse. Assim, a distribuição geográfica da produção científica não apenas reflete a capacidade de publicação de cada país, mas também revela redes internacionais de colaboração e a influência da diáspora acadêmica na disseminação do conhecimento.

Um dado que reforça essa observação é a discrepância entre os 446 documentos identificados ao incluir as palavras-chave “*Brasil*” e “*Brazil*”, a produção científica brasileira total de 2.117 publicações e o número de autores correspondentes brasileiros, que é 514. Essa diferença sugere que grande parte da produção científica brasileira não necessariamente aborda a realidade nacional, podendo estar inserida em estudos de caráter mais amplo ou em colaborações internacionais.

2.3.3.2 Cooperação internacional

Outro aspecto da colaboração internacional pode ser observado por meio dos países com o maior número autores correspondentes e de suas produções científicas com e sem participação de autores estrangeiros (Figura 2.5). Os dados apresentados evidenciam a predominância da produção científica sem colaboração internacional em todos os países analisados, mas com variações significativas no nível de cooperação internacional.

Figura 2.5 – Países com o maior número autores correspondentes e colaborações internacionais



Fonte: Elaborado pelos autores.

Os Estados Unidos lideram em número total de artigos (2.503), com a maior parte dessa produção sendo realizada sem colaboração internacional (2.156, equivalente a 86,1%). No entanto, ainda há uma quantidade expressiva de publicações com colaboração entre múltiplos países (347 artigos, 13,9% do total).

A China e o Reino Unido apresentam um perfil semelhante, com a maioria das publicações sendo de autoria nacional (73,5% e 73,6%, respectivamente). No entanto, a

colaboração internacional ainda tem um papel significativo nesses países, com 166 e 164 artigos publicados com parceiros de múltiplas nações, correspondendo a aproximadamente 26% do total de suas produções.

O Brasil e a Espanha, por outro lado, possuem um nível menor de colaboração internacional. No Brasil, 441 artigos (85,8%) foram publicados sem parceria estrangeira, enquanto apenas 73 artigos (14,2%) contaram com colaboração entre múltiplos países. A Espanha apresenta um padrão semelhante, com 278 publicações sem colaboração (79%) e 74 publicações com colaboração internacional (21%).


Esses dados reforçam que a produção científica em países como os Estados Unidos, China e Reino Unido tende a ser mais autônoma, com menor dependência de colaborações externas. Já o Brasil e a Espanha, apesar de apresentarem alguma integração internacional, ainda concentram a maior parte de suas publicações em redes de pesquisa nacionais. Esse cenário pode refletir fatores estruturais, como investimento em pesquisa, redes institucionais de colaboração e barreiras à internacionalização da produção científica.

2.3.3.3 Redes de conexões entre os países

A análise bibliométrica revelou a presença de uma rede de colaboração altamente estruturada entre os dez países mais conectados em publicações relacionadas à COVID-19 e fatores socioeconômicos. Os países com maior número de colaborações são Estados Unidos, Reino Unido, China, Espanha e Canadá, que constituem os principais centros desta rede. A forte interconexão entre esses países ressalta a importância da cooperação científica internacional na produção de conhecimento sobre os impactos da pandemia (Figura 2.6).

Os vínculos entre os países foram analisados levando em consideração a frequência de colaborações bilaterais em artigos científicos. Os relacionamentos mais fortes foram entre os Estados Unidos e o Reino Unido, os Estados Unidos e a China, e o Reino Unido e o Canadá, indicando a predominância de colaborações entre nações com tradição de pesquisa de alto impacto. Além disso, países europeus, como Espanha e Itália, também se destacaram por suas múltiplas interações com outras nações líderes no cenário mundial.

Figura 2.6 – Rede de conexões dos dez países mais conectados



Fonte: Elaborado pelos autores.

A visualização da rede revelou que os países centrais de colaboração exibem um alto grau de interconectividade, atuando como pontes para outros países na disseminação do conhecimento científico. Isso demonstra que, além da produção científica individual, as interações internacionais desempenham um papel fundamental na disseminação de descobertas e na construção de uma compreensão global dos impactos socioeconômicos da pandemia.

2.3.3.4 Palavras-chave mais utilizadas

Os principais termos identificados na análise bibliométrica refletem a importância dada pelas publicações aos impactos socioeconômicos da COVID-19 (Tabela 2.2). A palavra-chave mais frequente é “covid-19”, aparecendo em 2.415 publicações (6,75%), seguida de termos relacionados à demografia, como “mulher” (5,21%), “humano” (4,99%) e “homem” (4,82%), indicando que muitos estudos abordam os impactos diferenciados da pandemia entre diferentes grupos populacionais.

A relevância dos termos “socioeconomia” (3,57%) e “fatores socioeconômicos” (3,08%) evidencia o foco da pesquisa na relação entre a pandemia e as desigualdades

socioeconômicas. Além disso, termos como “pobreza” (0,83%) e “renda” (0,72%) reforçam essa preocupação.

A dimensão saúde mental também aparece com destaque, com termos como “depressão” (1,52%), “ansiedade” (1,29%), “psicologia” (1,19%) e “saúde mental” (1,18%), sugerindo que uma parcela considerável da produção científica aborda os efeitos psicológicos e emocionais da pandemia.

Metodologicamente, a presença de expressões como “estudo transversal” (1,16%), “estudo controlado” (1,12%) e “questionário” (0,98%) sugere que grande parte das pesquisas utiliza estudos transversais e questionários para avaliar os impactos da pandemia.

Países como “Estados Unidos” (1,68%), “Brasil” (0,77%) e “China” (0,71%) aparecem com frequência, refletindo o foco das publicações em contextos específicos e indicando que esses países têm sido amplamente estudados.

Por fim, a presença de termos como “vacinação” (0,73%), “prevenção e controle” (0,73%) e “saúde pública” (0,95%) sugere uma preocupação relevante com as estratégias de mitigação da pandemia e suas implicações para a saúde pública.

Tabela 2.2 – Principais palavras-chave encontradas nos artigos científicos

Termos	Frequência	Percentual	Termos	Frequência	Percentual
Covid-19	2415	6,75	Anxiety	462	1,29
Female	1866	5,21	Major clinical study	452	1,26
Human	1787	4,99	Psychology	425	1,19
Male	1727	4,82	Mental health	423	1,18
Humans	1578	4,41	Cross-sectional study	417	1,16
Adult	1551	4,33	Controlled study	401	1,12
Pandemic	1396	3,90	Epidemic	372	1,04
Coronavirus disease 2019	1367	3,82	Risk factor	354	0,99
Socioeconomics	1279	3,57	Socioeconomic-status	353	0,99
Aged	1159	3,24	Questionnaire	351	0,98
Article	1145	3,20	Public health	341	0,95
Middle aged	1144	3,20	Risk	328	0,92
Socioeconomic factors	1102	3,08	Cross-sectional studies	320	0,89
Epidemiology	866	2,42	Poverty	297	0,83
Pandemics	852	2,38	Sars coronavirus 2	291	0,81
Health	767	2,14	Mental-health	283	0,79
Adolescent	735	2,05	Betacoronavirus	278	0,78
Sars-cov-2	731	2,04	Age	275	0,77
Young adult	731	2,04	Brazil	274	0,77
United states	601	1,68	Care	271	0,76
Mortality	583	1,63	Stress	262	0,73
Depression	545	1,52	Prevention and control	260	0,73

Impact	545	1,52	Vaccination	260	0,73
Prevalence	536	1,50	Income	257	0,72
Child	527	1,47	China	255	0,71

Esses resultados indicam que a produção científica sobre a COVID-19 tem uma abordagem multidimensional, levando em consideração não apenas os aspectos biomédicos da doença, mas também seus impactos socioeconômicos e psicológicos e estratégias de controle.

2.3.3.5 Representação geográficas das universidades mais produtivas

Uma análise da representação geográfica das universidades mais produtivas em publicações sobre COVID-19 e fatores socioeconômicos revela uma alta concentração de pesquisas em poucos países. Os Estados Unidos lideram por uma ampla margem, abrigando 12 das 20 universidades mais produtivas, representando 58,46% da produção acadêmica (Tabelas 2.3 e 2.4). Esse domínio reflete o alto investimento dos Estados Unidos em ciência e tecnologia, além da forte tradição de pesquisa em instituições renomadas como Harvard, Stanford, Universidade de Washington e Universidade de Michigan.

Tabela 2.3 – Principais universidades em relação à produção científica sobre o tema

Afiliações	Artigos
UNIV TORONTO	213
UNIV OXFORD	207
UNIV WASHINGTON	192
UNIV CALIF SAN FRANCISCO	182
UNIV MICHIGAN	181
UNIV SAO PAULO	175
HARVARD MED SCH	171
UNIV HONG KONG	168
BOSTON UNIV	145
COLUMBIA UNIV	144
UNIV CHICAGO	144
UNIV PENN	140
CHINESE UNIV HONG KONG	138
JOHNS HOPKINS UNIV	126
UNIV EDINBURGH	126
KAROLINSKA INST	123
STANFORD UNIV	120
UNIV SOUTHERN CALIF	118
UNIV ILLINOIS	116
KINGS COLL LONDON	114

O Reino Unido e a China surgem como os outros dois principais centros acadêmicos. O Reino Unido tem três universidades (14,69%), incluindo a Universidade de Oxford e a Universidade de Edimburgo, que historicamente desempenharam um papel importante na pesquisa global. A China, por sua vez, abriga duas universidades (10,06%), com destaque para a Universidade de Hong Kong e a Universidade Chinesa de Hong Kong, demonstrando o crescimento acelerado do país como centro de inovação científica.

Tabela 2.4 – Representação geográficas das universidades mais produtivas

País	Número de Universidades	Representação geográfica (%)
Estados Unidos	12	58,46
Reino Unido	3	14,69
China	2	10,06
Canadá	1	7,00
Brasil	1	5,75
Suécia	1	4,04

Além dessas três nações que dominam a produção, outros países estão presentes no ranking, embora com um número menor de instituições. O Canadá contribui com 7,00%, representado exclusivamente pela Universidade de Toronto, uma das mais influentes da América do Norte. O Brasil se destaca com 5,75%, sendo a Universidade de São Paulo (USP) a única instituição latino-americana na lista, o que reflete sua importância nas pesquisas sobre os impactos da COVID-19. A Suécia, com 4,04%, é representada pelo Instituto Karolinska, que se destaca principalmente nas áreas biomédica e de saúde pública.

Essa distribuição evidencia a concentração da produção científica em países com tradição acadêmica consolidada, com grande influência dos Estados Unidos. Ao mesmo tempo, a presença de instituições de países emergentes, como o Brasil, sugere que a colaboração internacional e a diversificação da pesquisa científica estão aumentando. Esse cenário reforça a importância do intercâmbio acadêmico e da cooperação global na construção de conhecimento sobre os impactos da pandemia.

2.4 CONCLUSÕES

Este estudo revelou um panorama abrangente da produção científica sobre os impactos socioeconômicos da COVID-19 em diferentes escalas geográficas. A análise bibliométrica evidenciou um volume expressivo de publicações em níveis global e nacional, contrastando

com a produção limitada em Minas Gerais, o que pode refletir desafios relacionados à capacidade de pesquisa regional e à alocação de recursos.

Os resultados mostraram uma concentração de pesquisas em países com tradição acadêmica consolidada, além da importância das redes de colaboração científica para a disseminação do conhecimento.

A predominância da produção científica em países de alta renda e a concentração em instituições de pesquisa consolidadas reforçam a necessidade de promover maior diversidade geográfica e institucional nas colaborações acadêmicas. A análise das redes de coautoria evidenciou a importância das parcerias internacionais para a disseminação do conhecimento, mas também revelou desigualdades na distribuição do capital científico.

Adicionalmente, a frequência de termos relacionados à saúde mental, desigualdades socioeconômicas e vulnerabilidades populacionais destaca a relevância de abordagens interdisciplinares na compreensão dos efeitos da pandemia. Tais insights são cruciais para informar políticas públicas mais inclusivas e resilientes, especialmente em contextos marcados por desigualdades estruturais.

Por fim, este estudo contribui para o entendimento da evolução da produção científica sobre a COVID-19 e seus impactos socioeconômicos, apontando lacunas que podem orientar futuras pesquisas. A valorização da ciência regional, o fortalecimento da colaboração internacional e o foco em desigualdades socioeconômicas são como caminhos estratégicos para enfrentar desafios globais e locais em contextos de crise. A pesquisa contínua é essencial para mitigar desigualdades e fortalecer políticas públicas capazes de responder efetivamente a futuras crises globais.

3 WHAT ROLE DO SOCIAL VARIABLES AND HEALTH PLAY IN THE SPREAD OF COVID-19 IN THE STATE OF MINAS GERAIS – BRAZIL?²

Abstract

The high rates of COVID-19 lethality have made it necessary to identify groups potentially at risk from the disease. The spread of COVID-19 can be better understood with epidemiological studies combined with socioeconomic evaluations of the affected populations. This study aimed to use spatially explicit analysis to analyze the influence of socioeconomic and health attributes on the viral spread of COVID-19 in the state of Minas Gerais using multiple and spatial regressions. The socioeconomic data were collected using the platform of the Instituto de Pesquisa Econômica Aplicada (institute of Applied Economic Research). Subsequently, regression models were constructed, which included spatial error models (SEMs) and spatial lag models (SLMs) for the numbers of COVID-19 cases and deaths. For the socioeconomic and pandemic conditions found in the state of Minas Gerais, the SEM was the most suitable for the dependent variable Cases, while the SLM was the most suitable for the dependent variable deaths. The results show that municipalities with greater longevity among the citizens, better municipal urban infrastructure, and a lower flow of people on public transport had fewer deaths from COVID-19. This study provides support to pandemic risk mitigation policies and better management of medical resources.

Keywords: Epidemic outbreak, Infection spread, Social-demographic attributes, Epidemiologic models.

Resumo

A alta letalidade da COVID-19 traz evidente a necessidade da identificação dos potenciais grupos de risco da doença. A disseminação da COVID-19 pode ser melhor compreendida com estudos epidemiológicos combinados com avaliações socioeconômicas das populações afetadas. O objetivo desta pesquisa foi usar análise espacialmente explícitas para analisar a influência de atributos socioeconômicos e de saúde na disseminação viral de COVID-19 no estado de Minas Gerais por meio de regressões múltiplas e espaciais. Os dados socioeconômicos foram coletados na plataforma do Instituto de Pesquisa Econômica Aplicada, e posteriormente, foram construídos modelos de regressão incluindo modelos de erro espacial “spatial error models” (SEMs) e de defasagem espacial “spatial lag models” (SLMs) para as variáveis número de casos “Cases” e óbitos “Deaths” por COVID-19. Para as condições socioeconômicas e pandêmicas encontradas no estado de Minas Gerais, o SEM adequou-se melhor para variável dependente ‘Cases’ e o SLM para a variável dependente ‘Deaths’. Os resultados mostram que municípios com maior longevidade, infraestrutura urbana municipal, e menor fluxo de pessoas em transportes públicos apresentam menores ocorrências de óbitos por COVID-19. Este trabalho fornece subsídios a políticas de mitigação de risco de pandemia e melhor gerenciamento de recursos médicos.

Palavras-chave: Surto epidêmico, Propagação da infecção, Atributos sociodemográficos, Modelos epidemiológicos.

² Caderno de Geografia (2023) v.33, n.72. ISSN 2318-2962. DOI 10.5752/p.2318-2962.2023 v33 n.72 p.317 - Qualis A1 em Ciências Ambientais. Autores: Matheus Luiz Jorge Cortez; Úrsula Ruchkys de Azevedo; Edimar Olegário de Campos Júnior; Danilo Cirino Muniz do Nascimento; Anacleto Marito Diogo; Vagner Braga Nunes Coelho; David Soeiro Barbosa; Sônia Maria Carvalho Ribeiro

3.1 INTRODUCTION

COVID-19 is an acute respiratory disease originating from China, which was officially declared a public health emergency of international concern (PHEIC) by the World Health Organization (WHO) on January 30, 2020 (CAPODEFERRO; SMIDERLE, 2020; MATTHEW; ELUDOYIN; OLUWADIYA, 2021). More quickly than expected, the severe acute respiratory syndrome (SARS) caused by coronavirus was recognized as a disease of global medical interest, being declared a pandemic as of March 11, 2020. By June 28, 2021, data demonstrated 180,817,269 infected individuals and 3,923,238 deaths from the disease (WHO, 2021).

Viruses from the family *Coronaviridae* are capable of infecting mammals and other vertebrates. Among the microorganisms able to infect humans, most are responsible for flu-like symptoms (LANSIAUX et al., 2020). However, the SARS-CoV and MERS-CoV viruses cause serious, potentially fatal infections due to the lesions caused to the respiratory tract (HENNING et al., 2021).

Considering the high rates of COVID-19 lethality, attention should be given to the need to identify groups potentially at risk from the disease, and, consequently, promote socioeconomic data evaluation of the affected populations (KHALATBARI-SOLTANI et al., 2020a). Moreover, the use of social indicators should be adopted alongside the evaluation of epidemiological data, in view of the possibility of supporting pandemic risk mitigation policies and improving management of medical resources (HENNING et al., 2021).

In its most serious form, COVID-19 is most significant for the elderly population. One of the reasons is the greater occurrence of severe pulmonary infection among older patients, in addition to the increased levels of blood sugar hindering control of the infection, and the risk of cardiac death, according to Liu et al. (2020), who also suggest higher rates of comorbidities in this group.

Furthermore, the immunological system of an elderly individual is not as efficient as that of a young adult. When in a situation of comorbidity (such as obesity or arterial hypertension), the immunological system of the elderly establishes a condition of chronic inflammation, and when the patient is subjected to an infection, such as that caused by SARS-CoV-2, an exaggerated immunological response known as cytokine storm syndrome can occur (MEFTHAI et al., 2020). Thus, longevity represents a social indicator for the epidemiological dynamic of coronavirus.

Other social indicators such as low income and poor education may be related to increased vulnerability to COVID-19, as workers with this profile have greater difficulty carrying out their work in home-office and, therefore, are more exposed to viral transmission (ATCHISON et al., 2021; DE LAROCHELAMBERT et al., 2020).

Brazil has 27 federal states, among which, Minas Gerais (MG) stands out as the second most populous in the country, being composed of 853 municipalities (IBGE, 2021). By June 28, 2021, 1,788,725 cases and 45,924 deaths from COVID-19 had been confirmed in MG (SES-MG, 2021). Studies suggest that the Metropolitan Region of Belo Horizonte (RMBH) and the Vale do Rio Doce Mesoregion were the main epidemic focuses at the beginning of the expansion process and had an important influence on the spread of SARS-CoV-2 in the state of Minas Gerais. Regions such as the Triângulo Mineiro and Alto Paranaíba also presented elevated risk of infection from the disease (COURA-VITAL et al., 2021).

In this context, the aim of this study was to analyze the influence of socioeconomic and health attributes on the viral spread of COVID-19 in the state of Minas Gerais through multiple spatial regressions. While many studies have focused on public health variables, exploring the role of comorbidities in the spread of and deaths from COVID-19 (DE LUCENA et al., 2020; EJAZ et al., 2020; SANYAOLU et al., 2020; WANG et al., 2020a, 2020c), studies exploring the role of socioeconomic variables are less frequent (BAYODE et al., 2022; BENITA; GASCA-SANCHEZ, 2021; GREKOUSIS; WANG; LIU, 2021). The relevance of the theme is guided by better understanding of the influence of socioeconomic variables on the spread of COVID-19. This is information that could be used to assist public agents in the identification of regions with greater need for medical and hospital resources (BENITA; GASCA-SANCHEZ, 2021; GREKOUSIS; WANG; LIU, 2021).

3.2 METHODS


3.2.1 Characterization

This is an ecological, analytical study that evaluates how social context interferes in the health of the population in the Brazilian state with the second highest population in the country in relation to infection from COVID-19.

3.2.2 Description of the Study Area

The state of Minas Gerais is located in the southeast of Brazil (Figure 3.1), between 14°13'58" and 22°54'00" S and 39°51'32" and 51°02'35" W (Gov-MG, 2021). The state covers an area of 586,528.293 km² and is territorially divided into 853 municipalities, with a total population of 21,292,666 inhabitants and a demographic density of 36.30 inhab/km².

Figure 3.1 – Map of the location of Minas Gerais, Brazil.



Source: Prepared by the authors.

3.2.3 Variables considered in the study

Initially, documental research was carried out on the epidemiological attributes of the state of Minas Gerais (MG) (SES-MG, 2021), the socioeconomic data, which was collected from the platform of the Instituto de Pesquisa Econômica Aplicada (Institute of Applied Economic Research) (IPEA, 2021), and the data referring to the population of the municipalities of Minas Gerais (FJP, 2019) (Table 3.1).

Table 3.1 – Summary of the variables.

Variable	Abbreviation	Source	Scale
Vulnerability Rate	VR	(COSTA; MARGUTI, 2015)	Municipal
Urban infrastructure - Social Vulnerability Index	UI-SVI	(COSTA; MARGUTI, 2015)	Municipal
Longevity - Municipal Human Development Index	L-MHDI	(PINTO; COSTA; MARQUES, 2013)	Municipal
Aging Rate	AR	(PINTO; COSTA; MARQUES, 2013)	Municipal
COVID-19 cases	Cases	(SES-MG, 2021)	Municipal
COVID-19 Deaths	Deaths	(SES-MG, 2021)	Municipal
Standardized population	STD-P	Adapted from FJP (2019)	Municipal

Source: Prepared by the authors.

Among the variables made available by IPEA, the following were selected and evaluated: vulnerability rate (VR); the subindex of the municipal human development index (MHDI): MHDI-Longevity (L-MHDI); the subindex of the social vulnerability index (SVI): Urban Infrastructure (UI-SVI); and the Aging Rate (AR).

The VR and UI-SVI variables were developed by Costa and Marguti (2015) and are defined as follows: (i) VR is related to the percentage of people that live in households with a per capita income of less than half a minimum wage (R\$255,00 or \$141,50 in 2010, the year when the raw data was obtained through the demographic census) and that spend more than an hour to get to work in relation to the total number of people that live in households with a per capita income of less than half a minimum wage; (ii) the UI-SVI subindex is composed of indicators related to basic sanitation, garbage collection, and the urban mobility available to low-income families.

The L-MHDI subindex is related to life expectancy at birth (PINTO; COSTA; MARQUES, 2013), while the AR variable is composed of the percentage of people aged 65 and older in relation to the total municipal population.

Municipal population data updated by the Tribunal de Contas da União (Federal Court of Auditors) in 2019 (FJP, 2019) were also used. The population data were standardized (STD-P) to prevent the absolute population number from interfering in the statistical analysis. This variable was standardized using the Z-score method, whereby the values of each observation were subtracted from the mean of the variable and the result was divided by the value of the standard deviation. The result of these calculations is the Z value associated with the observation of interest.

The data referring to COVID-19 were obtained through the epidemiological bulletins of the Secretaria de Estado de Saúde de Minas Gerais (Minas Gerais State Health Secretary) (SES-MG, 2021). This database refers to the social and epidemiological data of the 853 municipalities in the target state. The data were individually organized and separated by each municipality. The number of cases and the number of deaths accumulated as a result of COVID-19 refer to the period of the first wave of infection in Brazil, from March to October 2020 (CERQUEIRA, EUGÊNIA et al., 2022).

A database was created from the obtained data, which was subsequently used to execute the multivariate regression analysis using R Core Team software (R Core Team, 2021).

No missing values were found among the data used. The absolute quantities of cases and deaths in the most populous municipalities are linked to the larger number of inhabitants in these places, which explains the outliers that were found. Removing these outliers from the function would result in a low degree of adjustment of the functions, as such, they were maintained in the analysis. Outliers are values that go beyond the upper and lower limits of the variable, which commonly occurs through typing errors or during data collection; however, in this case, the outlier occurs because Belo Horizonte is the city with the highest absolute numbers of COVID-19 cases and deaths in the state of Minas Gerais.

3.2.4 Statistical analyses

3.2.4.1 Spatial autocorrelation of the COVID-19 cases and deaths dependent variables

Global Moran's I was obtained using GeoDa software (ANSELIN; SYABRI; KHO, 2010) and a spatial association (autocorrelation) was verified between COVID-19 Cases and Deaths. Maps were then generated using Local Moran I (LISA), on which significant autocorrelated groupings were highlighted. The tests used the localizations y_i and the weighted mean of the neighboring values w_{yi} , which resulted in the Moran scatter plot represented by a straight line centered on the point of coordinates $y_i = 0$ and $w_{yi} = 0$, being thus divided into four quadrants. The upper-right quadrant and the lower-left quadrant correspond to positive associations, there being positive values surrounded by positive values in the upper-right quadrant and negative values surrounded by negative values in the lower-left quadrant. The lower-right and upper-left quadrants demonstrate negative associations, that is, in the lower-right quadrant there are positive values surrounded by negative values and in the upper-left quadrant, negative values surrounded by positive values (ANSELIN, 1995; CHI; ZHU, 2008).

3.2.4.2 Regression models


For the regression models, number of COVID-19 cases (Cases) and number of COVID-19 deaths (Deaths) were used as dependent variables, and the other variables were introduced through the Stepwise method (THOMPSON, 1995), as explanatory variables. Subsequently, the multiple linear regression (MLR) predictions were verified, and no transgression was found.

Global Moran's I was verified in the residuals of the two ordinary least squares (OLS) regression models for verification of spatial dependence in the errors, using the neighbors matrix for contiguity in the queen model. The Lagrange multiplier test (ASTAIZA-GÓMEZ, 2020) was then applied to select the spatial regression models to be applied to each of the two dependent variables. Significance at a level of 1% on the robust Lagrange multiplier test was adopted as selection criteria for the modelling method to be used for each set of variables. As such, the spatial error model (SEM) and the spatial lag model (SLM) were adjusted for the response variables of Deaths and Cases. The spatial error model adjustments were verified using the Hausman spatial test (KELLEY PACE; LESAGE, 2008). The spatial lag model adjustments were verified using simulation of the significance of direct and indirect impacts attributed to the independent variables used in each of the SLMs.

3.3 RESULTS

The spatialization of COVID-19 cases and deaths accumulated during the period corresponding to the first wave of infection (March to October 2020) for the municipalities in the state of Minas Gerais is presented first (Figure 3.2).


Figure 3.2 – Spatialization of COVID-19 data in the state of Minas Gerais, Brazil. Data accumulated from March 2020 to the end of October 2020. A) Distribution of cases due to SARS-CoV-2 infection. B) Distribution of deaths.



Source: Prepared by the authors.

Through the application of Global Moran's I, the existence of a spatial autocorrelation was found in the data on number of COVID-19 cases and deaths in relation to the populations of the municipalities of Minas Gerais (Figure 3.3).


Figure 3.3 – Global Moran scatter plot for variables of cases and deaths from SARS-CoV-2 in the state of Minas Gerais, Brazil (Mar-Oct. 2020).



Source: Prepared by the authors.

Through analysis of the Moran scatter plots, a positive spatial autocorrelation was found, in which municipalities with high numbers of COVID-19 cases or deaths tended to be surrounded by neighboring municipalities also with high numbers of cases or deaths. The same principle can be observed for municipalities with low numbers of COVID-19 cases or deaths. For better visualization of the spatial autocorrelation, Local Moran's Is were calculated (Figure 3.4).

Figure 3.4 – Spatial autocorrelation in the first wave of COVID-19 in the state of Minas Gerais, Brazil. 4A. Autocorrelation map of cases. 4B. Autocorrelation map of deaths.



Source: Prepared by the authors.

The multiple linear regression models (MLRs) for the different sets of variables were better adjusted when the Stepwise method was used. The MLR models have distinct explanatory variables (independent) for the response variables (dependent) of numbers of COVID-19 cases and deaths.

The model defined for the number of cases indicated two significant independent variables. This model and the explanatory variables can be seen in Table 3.2.

Table 3.2 – OLS regression for the dependent variable Cases.

	Estimate	Std. Error	t value	Pr(> t)	Tolerance	VIF
Intercept	167.2840	45.3670	3.6870	0.0002	-	-
STD-P	2071.6560	29.6130	69.9580	0.0000	0.9639	1.0374
VR	-15.4870	5.6620	-2.7350	0.0064	0.9639	1.0374

Multiple R-squared: 0.8549, Adjusted R-squared: 0.8546
F-statistic: 2505 on 2 and 850 DF, p-value: < 2.2e-16

Source: Prepared by the authors.

The first MLR model was significant, explaining the behavior of 85.46% of the number of cases through these two independent variables. According to the variance inflation factor (VIF) value for each explanatory variable, there was no multicollinearity between the variables.

For the MLR model with COVID-19 deaths as the dependent variable, five independent variables were found. The model had adjusted R^2 of 94.04% (Table 3.3).

Table 3.3 – OLS regression for the dependent variable Deaths.

	Estimate	Std. Error	t value	Pr(> t)	Tolerance	VIF
Intercept	41.4169	16.5355	2.5050	0.0124	-	-
Cases	0.0266	0.0002	112.3020	0.0000	0.9377	1.0664
VR	0.7081	0.1733	4.0860	0.0000	0.3169	3.1551
AR	0.5855	0.2635	2.2220	0.0265	0.9602	1.0415
L-MHDI	-58.7739	19.4907	-3.0150	0.0026	0.7707	1.2976
UI-SVI	-18.6187	7.3303	-2.5400	0.0113	0.2904	3.4434
Multiple R-squared: 0.9408, Adjusted R-squared: 0.9404						
F-statistic: 2691 on 5 and 847 DF, p-value: < 2.2e-16						

Source: Prepared by the authors.

The variable with the greatest impact on the function was the number of COVID-19 cases, given that it is not possible to have deaths from the disease without having cases of the same. The second most important explanatory variable was VR, followed by L-MHDI, UI-SVI, and AR, respectively. It is noteworthy that the explanatory variables of Cases, VR, and AR are directly proportional, contrasting with the variables L-MHDI and UI-SVI.

After confirming the existence of a spatial autocorrelation in the residuals of the OLS models through Global Moran's I (Cases = 0.1033; Deaths = 0.0949), the Lagrange multiplier test was applied to verify the method of the spatial model to be applied (Table 3.4).

Table 3.4 – Lagrange multiplier test

	Test	Result	p-value
Deaths	Lmerr	20.1940	7.00E-06
	Lmlag	22.4120	2.20E-06
	RLMerr	10.4500	1.23E-03
	RLMlag	12.6680	3.72E-04
Cases	Lmerr	23.9100	1.01E-06
	Lmlag	0.0998	7.52E-01
	RLMerr	31.4910	2.00E-08
	RLMlag	7.6810	5.58E-03

Source: Prepared by the authors.

There was a greater level of significance for the spatially lagged spatial dependence structure for the dependent variable Deaths than for the autocorrelation structure in errors, when robust diagnostic tests were taken into consideration (MLRlag and MLRerr, respectively). The opposite was observed for the dependent variable Cases.

Considering the criterion of 1% significance on the robust Lagrange multiplier diagnostic test, both spatial models, SEM and SLM, were selected to model the dependent variables of Cases and Deaths. Adjustments to the spatial models were found from the sets of variables that best modelled the respective dependent variables through MLR (Tables 3.5, 3.6, 3.7, and 3.8). The result of the Hausman spatial test for validation of the adjusted SEM models can be observed in Tables 3.5 and 3.6.

Table 3.5 – Spatial Error Model for the dependent variable Cases

	Estimate	Std. Error	z value	Pr(> z)
Intercept	153.5790	51.1049	3.0052	0.0027
STD-P	2085.6600	29.6845	70.2609	0.0000
VR	-12.8595	5.8593	-2.1947	0.0282
Lambda: 0.20437, LR test value: 18.363, p-value: 0.000018256				
Wald statistic: 16.034, p-value: 0.00006221				
Spatial Hausman test = 5.1663, df = 3, p-value = 0.16				

Source: Prepared by the authors.

Table 3.6 – Spatial Error Model for the dependent variable Deaths

	Estimate	Std. Error	z value	Pr(> z)
Intercept	31.3724	16.9979	1.8457	0.0649
Cases	0.0265	0.0002	113.0656	0.0000
VR	0.3518	0.1812	1.9414	0.0522
AR	0.7191	0.2844	2.5282	0.0115
L-MHDI	-47.9822	20.1030	-2.3868	0.0170
UI-SVI	-7.2494	7.6786	-0.9441	0.3451
Lambda: 0.24093, LR test value: 19.906, p-value: 0.0000081342				
Wald statistic: 23.194, p-value: 0.0000014648				
Spatial Hausman test = 64.599, df = 6, p-value = 5.21e-12				

Source: Prepared by the authors.

Table 3.7 – Spatial Lag Model for the dependent variable Cases

	Estimate	Std. Error	z value	Pr(> z)
Intercept	167.6076	45.2865	3.7010	0.0002
STD-P	2073.4858	30.2929	68.4479	0.0000
VR	-14.9066	6.0197	-2.4763	0.0133
Rho: -0.0074912, LR test value: 0.096132, p-value: 0.75652				
Wald statistic: 0.092352, p-value: 0.76121				

Source: Prepared by the authors.

Table 3.8 – Spatial Lag Model for the dependent variable Deaths

	Estimate	Std. Error	z value	Pr(> z)
Intercept	37.3502	16.2514	2.2983	0.0215
Cases	0.0264	0.0002	111.9597	0.0000
VR	0.3195	0.1827	1.7483	0.0804
AR	0.7694	0.2611	2.9471	0.0032
L-MHDI	-56.5489	19.1499	-2.9530	0.0031
UI-SVI	-8.5403	7.3824	-1.1568	0.2473
Rho: 0.079466, LR test value: 23.117, p-value: 0.0000015241				
Wald statistic: 24.66, p-value: 0.00000068404				

Source: Prepared by the authors.

In addition, the impacts of the independent variables used in the spatial lag models were measured (Tables 3.9 and 3.10). Inferences on the direct and indirect impacts related to the parameters obtained for the independent variables of the spatial lag model were simulated using the Markov Chain Monte Carlo (MCMC) estimation method for Bayesian inference (GELFAND et al., 1990; LESAGE, 1997; LESAGE; PACE, 2009).

Table 3.9 – Spatial Lag Model impact tests for Cases

	Variables	Direct	Indirect	Total
Impact measures	STD-P	2073.5060	-15.4376	2058.0684
	VR	-14.9067	0.1110	-14.7957
Simulated z-values	STD-P	70.5097	-0.3429	40.5894
	VR	-2.5453	0.2114	-2.4965
Simulated p-values	STD-P	0.0000	0.7316	0.0000
	VR	0.01092	0.83261	0.012542

Source: Prepared by the authors.

Table 3.9 shows the simulated p-values for the SLM impacts for the dependent variable Cases. The independent variables STD-P and VR had significant direct impacts and insignificant indirect impacts.

Table 3.10 – Spatial Lag Model impact tests for Deaths

	Variables	Direct	Indirect	Total
Impact measures	Cases	0.0264	0.0022	0.0287
	VR	0.3198	0.0272	0.3471
	AR	0.7703	0.0655	0.8358
	L-MHDI	-56.6127	-4.8178	-61.4306
	UI-SVI	-8.5500	-0.7276	-9.2776
Simulated z-values	Cases	118.3050	5.0383	58.6114
	VR	1.7849	1.7663	1.7962
	AR	2.8907	2.3556	2.8704
	L-MHDI	-2.9474	-2.5188	-2.9458
	UI-SVI	-1.0653	-1.0241	-1.0656
Simulated p-values	Cases	0.0000	0.0000	0.0000
	VR	0.0743	0.0773	0.0725
	AR	0.0038	0.0185	0.0041
	L-MHDI	0.0032	0.0118	0.0032
	UI-SVI	0.2867	0.3058	0.2866

Source: Prepared by the authors.

However, the impact tests in relation to the SLM for the dependent variable Deaths (Table 3.10) demonstrated that the variables UI-SVI and VR were not significant at the 5% level of probability. On the other hand, the independent variables Cases, AR, and L-MHDI had significant direct and indirect impacts.

3.4 DISCUSSION

Through the analysis of the results, it was possible to perceive that there was no great spatial dependence in the disposition of the numbers of COVID-19 cases and deaths. However, clusters were identified in certain regions of the state through positive spatial autocorrelation, that is, locations with positive values were surrounded by neighbors with positive values and locations with negative values were surrounded by neighbors with negative values. Moreover, the variables that were significant in the Linear Regression Models indicate that the independent variables influenced the numbers of cases and deaths.

It is noteworthy that the variables that explain the behavior of the variables Cases and Deaths were different when the multiple regression models were analyzed. For the dependent variable Cases, the number of inhabitants and the vulnerability rate managed to explain 85.46% of the observations; whereas for Deaths (adjusted $r^2 = 94.04\%$), the independent variable with the greatest significance was Cases, followed by VR.

Through the application of the Lagrange multiplier test on the OLS residuals, significant values were obtained in relation to the spatial dependence structure (Table 3). The SLM and SEM were selected for Cases and Deaths due to the robust diagnostic test results. With the application of the robust tests, possible interference of the spatial autocorrelation in the errors was considered, when spatially lagged dependence of the variables and vice-versa were evaluated (ANSELIN et al., 1996).

Evaluation of the OLS and SEM models through application of the Hausman spatial test, enabled the inference that the analogue coefficients estimated for the set of variables with the dependent variable Deaths were statistically different (p-value = 0.00). However, the insignificant p-value (0.16) of the Hausman spatial test for the OLS and SEM models for the dependent variable Cases indicated that the coefficients of the parameters did not differ statistically (KELLEY PACE; LESAGE, 2008). Therefore, it was considered that the adjustment of the OLS and SEM models was suitable for Cases and unsuitable for Deaths. Nevertheless, it is worth emphasizing that the OLS models resulted in high R^2 values and that the p-values of the autoregressive coefficients of the SEM models were significant ($\lambda_{Cases} = 0.000018256$ and $\lambda_{Deaths} = 0.0000081342$).

When analyzing the variables of the SLM models after carrying out the tests, the direct and indirect impacts of the variables can be interpreted separately. According to LeSage and Pace (LESAGE; PACE, 2009), the changes observed in the independent variables in relation to a given municipality can potentially affect the dependent variable in the other municipalities.

In the SLM for Cases, the independent variable STD-P demonstrated a direct impact on the increase in COVID-19 cases within municipalities, with no evidence of indirect effects. This result indicates that municipalities with larger populations reported a higher number of cases, reflecting the direct influence of population density on virus transmission.

Conversely, the SLM revealed that the variable VR contributed to a direct reduction in COVID-19 cases in the analyzed municipalities. This pattern was consistent with findings from the SEM and MLR models for the dependent variable Cases. These findings underscore the complexity of the relationships between socioeconomic factors and the spread of SARS-CoV-2, as they contradict initial expectations that low-income populations, who often rely on public transportation for longer commutes, would be more vulnerable to COVID-19.

A possible explanation for this outcome may be the implementation of the emergency financial aid program by the Brazilian federal government, which enabled many individuals in these populations to remain at home during the most critical periods of the pandemic. Additionally, in some cases, vulnerable populations in large cities adopted more cautious

behaviors, such as stricter adherence to preventive measures (mask-wearing and social distancing), challenging the initial assumption that these groups would be more susceptible to higher rates of infection and mortality (GARNIER et al., 2021). Instead, the opposite effect was observed, with reductions in both cases and deaths among these groups.

Regarding the SLM for 'Deaths,' the independent variables VR and UI-SVI did not demonstrate statistical significance at the 5% probability level. This lack of significance was also observed in the SEM for 'Deaths.' However, in the MLR model, both variables were statistically significant in explaining COVID-19-related mortality. This divergence among the models highlights the sensitivity of these variables to the specific characteristics of each modeling approach, suggesting the need for complementary analyses to better understand their influence on mortality outcomes.

The independent variable L-MHDI, related to longevity of the population, had significant direct and indirect impacts in the SLM model for Deaths. The result indicates that in municipalities where the population achieves greater longevity, and in the neighboring municipalities, there was a reduced number of COVID-19 deaths as the coefficient of the variable had a negative value. According to Pinto et al. (2013), a higher L-MHDI value in a given municipality may suggest that there are better living conditions and access to health services for the resident population. As such, the direct and indirect impacts of the variable L-MHDI may be associated with the hospital infrastructure existing in each municipality and the access available to the resident and floating population (from neighboring cities).

Also regarding SLM for the dependent variable Deaths, it was found that the independent variable AR directly and indirectly impacts the number of deaths in the municipalities of the state of Minas Gerais. The direct impact of the variable was the most significant for the model ($p\text{-value} = 0.0032$ against 0.0118) and demonstrates that in municipalities with a higher aging rate there was a greater number of COVID-19 deaths. This result reiterates the findings of Liu et al. (2020) and Mefhati et al. (2020), who stated that the increased frailty (cellular and systemic) of the elderly, combined with contamination from the disease, can lead to more severe pulmonary infections and trigger immunological complications, which increases the chance of lethality for these individuals.

COVID-19 spread throughout the state of Minas Gerais and, as reported by Oronce et al. (2020), certain socioeconomic factors have been identified as relevant to increasing the probability of transmission and deaths from the disease. Regions with larger populations where a considerable portion of the population are found in a situation of vulnerability

(SANNIGRAHI et al., 2020; YILDIRIM; GEÇER; AKGÜL, 2021), as in the Metropolitan Region of Belo Horizonte and the west of the state, were severely affected by the disease.

The present study shows that municipalities with populations with greater longevity, better municipal urban infrastructure, and a lower flow of people on public transport present less COVID-19 deaths. Therefore, this study provides support to mitigating the spread of the disease, emphasizing the need for investment in the cleaning and maintenance of transport infrastructure in areas with higher transmission rates. A study carried out in Turkey identified prominent preventative practices against COVID-19, such as limitations on the use of collective transport and the frequent washing of hands. In the United States, Karmakar et al. (2021) identified that in counties where there was greater social vulnerability, there were higher rates of transmission and death from the disease.

It can be observed through this study that each dependent variable was best explained by distinct spatial regression models. For the socioeconomic and pandemic conditions found in the state of Minas Gerais, SEM was most suitable for the dependent variable Cases, and SLM was most suitable for the dependent variable Deaths.

3.5 CONCLUSIONS

It was observed in this study that spatial regression models are important for studies involving socioeconomic variables and their relationships with COVID-19, especially SLM, due to the possibility of individual evaluation of the direct and indirect impacts associated with each independent variable used in the models. It has been conclusively demonstrated that municipalities with greater longevity and better municipal urban infrastructure had less COVID-19 deaths. These findings value the evaluation of socioeconomic data for the contention of diseases such as COVID-19, or even for directing healthcare and financial resources to places of risk.

4 IVT_{SARS-COV-2}: UM ÍNDICE MULTICRITÉRIO E A DINÂMICA URBANA EM MINAS GERAIS, BRASIL³

RESUMO

Objetivo: Este estudo teve como principal objetivo desenvolver um índice de vulnerabilidade municipal à transmissão do SARS-CoV-2 em Minas Gerais, integrando fatores socioeconômicos, estruturais e epidemiológicos. Foram identificadas variáveis determinantes para a distribuição espacial da COVID-19 e classificados os 853 municípios segundo níveis de vulnerabilidade. O trabalho oferece subsídios para formulação de políticas públicas, promovendo alocação estratégica de recursos para mitigação de crises futuras.

Métodos: Dados de casos de COVID-19 de fevereiro de 2022 foram associados a variáveis socioeconômicas (empregos por setor, densidade de veículos, índices de vulnerabilidade social e lazer), mobilidade urbana (corredores rodoviários) e urbanização. Utilizou-se um modelo de análise multicritério (ADMC), ponderando as variáveis por correlações de Pearson com o número de casos. A validação cruzada foi aplicada para garantir a consistência dos resultados.

Resultados: O índice de vulnerabilidade variou de 1 a 8, com maior risco identificado em municípios de maior dinamismo, como Belo Horizonte, Uberlândia e Contagem, devido à alta densidade populacional, conectividade rodoviária e predominância de ocupações em comércio e serviços. A área urbana foi a variável mais influente (22,92% do peso), seguida pela conectividade rodoviária (17,54%). Municípios menos conectados e com menor densidade populacional apresentaram menor vulnerabilidade.

Conclusão: O índice revelou discrepâncias regionais e destacou o impacto de fatores críticos, como urbanização e mobilidade, na disseminação do vírus. Apesar de limitações, como subnotificação e ausência de variáveis comportamentais, o IVT_{SARS-CoV-2} mostrou-se uma ferramenta valiosa para planejamento sanitário e aplicação em outras doenças transmissíveis. A integração de tecnologias emergentes e medidas sustentáveis pode reduzir riscos de futuras pandemias e melhorar a qualidade de vida.

Descritores: COVID-19. Análise de decisão multicritério. Fatores Socioeconômicos. Corredores urbanos. Fragmentos urbanos.

³ Artigo submetido ao periódico Revista de Saúde Pública (em análise). Autores: Matheus Luiz Jorge Cortez; Úrsula Ruchkys de Azevedo; Sônia Maria Carvalho Ribeiro; Anacleto Marito Diogo; Danilo Cirino Muniz do Nascimento

4.1 INTRODUÇÃO

A pandemia da COVID-19 surpreendeu o mundo, impondo um verdadeiro teste de resiliência para às sociedades humanas em diferentes contextos. Entre os fatores de risco associados à doença, destaca-se um elemento intrínseco à vida moderna: a convivência em comunidades permanentes. Desde a transição das sociedades caçadoras-coletoras para as sedentárias, a organização social e urbana tem desempenhado um papel crucial na disseminação de doenças infecciosas.

As desigualdades socioeconômicas têm um impacto significativo na saúde da população global (BAMBRA et al., 2020; GOLDMAN, 2001; MACKENBACH et al., 2008). No contexto da COVID-19, as características socioeconômicas de diferentes grupos populacionais têm sido correlacionadas a diversos desfechos, em relação à taxa de propagação viral, gravidade dos casos e taxa de mortalidade (CAMPOS et al., 2021; CIFUENTES et al., 2021; CORTEZ et al., 2023; QUAN et al., 2021; SIQUEIRA et al., 2023). Além disso, a conectividade urbana pode exercer um papel importante na transmissão de doenças (CONNOLLY; KEIL; ALI, 2021; KOEHL, 2021; TELLER, 2021). Portanto, compreender a distribuição dos fatores que influenciam a transmissão do SARS-CoV-2, considerando uma combinação de características sociodemográficas, econômicas e de mobilidade, é essencial para identificar regiões onde as populações são mais susceptíveis ao vírus (ALVES et al., 2023).

No contexto da COVID-19, a análise da vulnerabilidade regional é essencial para subsidiar estratégias de mitigação e alocação eficiente de recursos. Métodos de análise de decisão multicritério (ADMC) têm sido amplamente empregados na epidemiologia para integrar variáveis sociodemográficas, econômicas e de mobilidade, permitindo a classificação de unidades territoriais segundo seu nível de suscetibilidade (DE ALMEIDA et al., 2017; DOM et al., 2016; LI et al., 2017; ZHAO et al., 2020). Diversos estudos utilizaram ADCMC para identificar áreas mais propensas à infecção pelo SARS-CoV-2 e para investigar os fatores associados à transmissão (CAMPOS et al., 2021; MISHRA; GAYEN; HAQUE, 2020; SANGIORGIO; PARISI, 2020), fornecendo ferramentas relevantes para a formulação de políticas públicas (HAWKINS; CHARLES; MEHAFFEY, 2020; HENNING et al., 2021; KHALATBARI-SOLTANI et al., 2020b; SANTOS et al., 2021).

A Agenda 2030 da Organização das Nações Unidas (ONU) destaca, por meio do Objetivo de Desenvolvimento Sustentável 3 (ODS-3), a importância de “garantir o acesso à saúde de qualidade e promover o bem-estar para todos, em todas as idades” (ONU, 2022). O subitem “3.d” enfatiza a necessidade de reforçar a capacidade global para alerta precoce e

gerenciamento de riscos à saúde, um princípio diretamente alinhado aos desafios impostos pela pandemia.


Minas Gerais, o segundo estado mais populoso do Brasil, contava com uma população estimada de 20.539.989 habitantes em 2022, distribuída por seus 853 municípios (IBGE, 2025a). Em 28 de julho de 2022, o estado registrou 3.809.396 casos confirmados de COVID-19 e 62.866 óbitos em decorrência da doença (SES-MG, 2022), evidenciando a gravidade da crise sanitária e a importância de estratégias direcionadas para enfrentar pandemias futuras.

Este trabalho tem como objetivo principal desenvolver um índice de vulnerabilidade municipal à transmissão do SARS-CoV-2 em Minas Gerais, integrando fatores socioeconômicos, demográficos e de mobilidade. Os objetivos específicos incluem: (1) identificar variáveis socioeconômicas de atualização periódica e disponibilidade em nível municipal que possam explicar a distribuição de casos de COVID-19; (2) classificar os 853 municípios do estado conforme seu nível de vulnerabilidade; e (3) analisar as relações entre variáveis socioeconômicas e o aumento da susceptibilidade à transmissão do vírus. A espacialização dos níveis de vulnerabilidade poderá servir como subsídio para formulação de políticas públicas voltadas à prevenção e mitigação de danos causados por pandemias, promovendo maior resiliência do território mineiro.

4.2 METODOLOGIA

A metodologia foi estruturada em várias etapas, organizadas para atender aos objetivos do estudo (Figura 4.1).

Figura 4.1 – Fluxograma simplificado da metodologia desenvolvida.



Fonte: Elaborado pelos autores.

4.2.1 Dados da COVID-19

Os dados de casos de COVID-19 (C-COV) foram obtidos em escala municipal Minas Gerais, com base nas informações compiladas pela Secretaria de Estado de Saúde de Minas Gerais (SES-MG, 2025b).

O mês de fevereiro de 2022 foi selecionado devido ao expressivo aumento de casos impulsionado pela variante Ômicron, conhecida por sua elevada transmissibilidade (BUTANTAN, 2022). Esse recorte captura um momento crítico da pandemia, quando o sistema de saúde enfrentou alta pressão. A escolha assegura a análise de um período de alta transmissão, mantendo a homogeneidade na avaliação dos fatores influentes.

Ressalta-se a subnotificação de casos de COVID-19 no estado, tanto de graves quanto leves ou assintomáticos (ORELLANA et al., 2021; PRADO et al., 2020; RIBEIRO; BERNARDES, 2020). Essa limitação pode subestimar a real extensão da transmissão viral.

4.2.1 Dados de cobertura do solo – corredores

Os corredores urbanos, incluindo ruas, avenidas e rodovias, influenciam a propagação do SARS-CoV-2. Sua densidade e extensão ampliam a exposição ao vírus e a disseminação nos municípios (CHANG et al., 2021).

Os dados referente às vias municipais foram obtidos do arquivo vetorial “roads”, disponibilizado pela plataforma OpenStreetMap (OSM, 2025a). Amplamente utilizados na pandemia, esses dados basearam análises de mapeamento de zonas de risco, caracterização de vias urbanas e análise das relações entre o risco de infecção pelo SARS-CoV-2 e diferentes configurações das redes rodoviárias (KWOK et al., 2021; MINGHINI; SARRETTA; NAPOLITANO, 2022; MOONEY et al., 2021; WANG et al., 2021).

4.2.1.1 Rasterização dos dados de corredores

Os dados vetoriais dos corredores foram rasterizados com resolução de 10 metros por pixel, representando à largura média das vias identificadas. A combinação com os limites municipais de Minas Gerais permitiu a quantificação de pixels em cada município.

As áreas totais dos corredores (A-COR) para cada município foram calculadas pela fórmula:

$$\text{Área total}_{\text{Corredores}} = n^{\circ} \text{ de pixels} \times \text{área do pixel} \quad 1$$

Onde:

- *n° de pixels* representa a quantidade de pixels contidos dentro dos limites municipais;
- *área do pixel* é calculada como *lado*², sendo o lado do pixel igual a 10 metros.

Esses valores foram rasterizados com resolução de 30 metros por pixel, garantindo compatibilidade com a coleção 7.0 do MapBiomas (MAPBIOMAS, 2025). Cada pixel recebeu o valor correspondente à área total de corredores do município em quilômetros quadrados.

4.2.3 Dados de cobertura do solo – área urbana

Os dados de uso e cobertura do solo foram obtidos no arquivo raster da coleção 7.0 Projeto MapBiomas de 2021 (MAPBIOMAS, 2025). A partir desse raster foi extraídos os dados de cobertura urbana dos municípios (A-URB).

O procedimento de contagem de pixels, cálculo da área com cobertura urbana e rasterização seguiu as mesmas etapas descritas para a classe corredores. A área de cobertura urbana de cada município foi calculada em números absolutos (km²) e utilizada diretamente nas análises do presente trabalho.

4.2.4 Dados socioeconômicos

Os dados socioeconômicos foram adquiridos em escala municipal (FJP, 2019a). Com base nos estudos de De Angelis et al. (2021) e Yoshikawa e Kawachi (2021), foram selecionados os seguintes indicadores socioeconômicos como variáveis independentes para esta pesquisa: 1) empregos do setor de serviços (EFS); 2) empregos do setor de comércio (EFC); 3) empregos do setor da indústria da construção (EFIC); 4) empregos do setor da indústria de transformação (EFIT); 5) densidade de veículos (DV); 6) Índice Mineiro de Responsabilidade Social – Vulnerabilidade (IMRS-V) e 7) Índice Mineiro de Responsabilidade Social – Cultura, Esportes e Lazer (IMRS-CEL). Os indicadores foram escolhidos devido à sua relevância na caracterização socioeconômica municipal e à sua relação direta com os objetivos desta pesquisa.

Os dados de densidade de veículos foram obtidos em unidades por quilômetro quadrado (veículos/km²). Já os dados de empregos por setor econômico foram convertidos em dados percentuais, calculados em relação ao total de habitantes dos respectivos municípios.

No software QGIS, os valores das variáveis foram associados às áreas municipais correspondentes por meio da junção de uma tabela em formato .csv, que continha os dados socioeconômicos, com a tabela de atributos do arquivo vetorial municipal de Minas Gerais. A junção foi realizada utilizando o campo de identificação único (código IBGE), garantindo a integridade e precisão dos dados. Após a junção, os dados foram rasterizados para permitir sua integração no modelo de ADMC.

4.2.5 Modelo de análise multicritério

O modelo para desenvolvimento da ADMC e obtenção do índice de vulnerabilidade à transmissibilidade de SARS-CoV-2 foi criado no software DINAMICA EGO (SOARES-FILHO; COUTINHO CERQUEIRA; LOPES PENNACHIN, 2002).

Inicialmente, o processo consistiu na atribuição de notas aos valores das variáveis independentes. Em seguida, essas notas foram ponderadas por meio da multiplicação pelos pesos atribuídos a cada variável. A soma das notas ponderadas de cada variável independente gerou o índice de vulnerabilidade à transmissibilidade do SARS-CoV-2 ($IVT_{SARS-CoV-2}$) em âmbito municipal.

A metodologia utilizada para atribuição de notas aos valores das variáveis independentes dos municípios de Minas Gerais envolveu: 1) a divisão do valor máximo de cada

variável por dez, estabelecendo-se a amplitude de classe; 2) a determinação dos limites superiores das classes; 3) a atribuição de notas às variáveis conforme seus valores, ou seja, cada município recebeu nota (entre 1 e 10) para cada variável independente de acordo com o limite superior da classe daquela variável. Nos casos onde a variável foi igual a zero atribuiu-se nota zero.

Essa abordagem permitiu uma distribuição proporcional das notas com base nos valores das variáveis, facilitando a comparação e análise dos dados. Desta maneira, foi possível a atribuição de onze notas para cada uma das variáveis de entrada no modelo de análise multicritério.

A atribuição de pesos às variáveis foi realizada com base nos valores de correlação de Pearson entre as variáveis selecionadas e o número de novos casos de COVID-19 registrados em fevereiro de 2022 (SINHASTHITA; JEARANAITANAKIJ, 2020). Essa abordagem baseada em dados, aliada à espacialização do conjunto de variáveis, contribui para aprimorar a qualidade das informações disponíveis e auxilia na extração de conhecimento significativo para a tomada de decisões (ALI et al., 2020).

Os valores de correlação de Pearson foram somados, e o percentual de contribuição de cada variável em relação ao total foi calculado. Esses percentuais foram convertidos para uma escala entre zero e um, dividindo-os por 100. A soma dos pesos atribuídos às nove variáveis resultou em um valor igual a um, garantindo a proporcionalidade entre elas. O índice final, proposto para cada município, variou entre 0 e 10, onde 0 representava uma pontuação nula em todas as variáveis e 10 indicava pontuação máxima (nota 10) em todas as variáveis. Essa padronização permite a comparação direta da vulnerabilidade à transmissibilidade da COVID-19 entre os municípios analisados.

O índice de vulnerabilidade à transmissibilidade do SARS-CoV-2 ($IVT_{SARS-CoV-2}$) pode ser calculado por meio da aplicação do modelo de análise multicritério, cuja formulação genérica é expressa pela seguinte equação:

$$IVT_{SARS-CoV-2} = \sum_{i=1}^n (p_i \times x_i) \quad 2$$

Onde:

- $IVT_{SARS-CoV-2}$ é o valor do índice obtido para o município;

- p_i representa o peso atribuído à variável i ;
- x_i é a nota da variável i no âmbito municipal;
- n é o número total de variáveis considerados.

4.2.5 Validação cruzada

Diferentemente da abordagem tradicional de validação cruzada empregada em aprendizado de máquina, que consiste no treinamento e teste de modelos preditivos, neste estudo foi adotada uma abordagem adaptativa para avaliar a solução obtida por meio do método de análise multicritério. Essa abordagem permitiu validar o modelo considerando a coerência e a consistência das variáveis selecionadas em relação aos resultados gerados.

Para realizar a validação cruzada do modelo gerado por meio do método de análise multicritério aplicado aos dados socioeconômicos dos municípios mineiros, foi utilizado o pacote *scikit-learn* no ambiente Python (PEDREGOSA et al., 2011). No código executável, foram inseridos os coeficientes do modelo e as notas atribuídas às variáveis independentes, tratadas diretamente como variáveis do modelo. Para a variável dependente, utilizou-se o resultado da classificação de vulnerabilidade calculado para cada município.

Por meio do método de validação cruzada, o conjunto de dados é particionado em k folds. O modelo é treinado em $k-1$ folds e avaliado no fold restante. Esse processo é repetido k vezes, de modo que cada fold seja utilizado como conjunto de teste uma vez. A performance do modelo, medida pelo Erro Quadrático Médio (EQM), é calculada em cada iteração. A média desses valores fornece uma estimativa robusta do desempenho do modelo em dados não vistos. A validação cruzada é fundamental para evitar o sobreajuste, um problema que ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar (ARLOT; CELISSE, 2010; BISHOP; NASRABADI, 2006; BROWNE, 2000; PEDREGOSA et al., 2011).

4.3 RESULTADOS

As variáveis analisadas apresentaram diferentes graus de correlação com o número de novos casos de COVID-19 registrados em fevereiro de 2022. Com base na intensidade dessas correlações, os pesos para o ADMC foram calculados, de modo a refletir a relevância de cada variável no modelo. Os detalhes dos pesos atribuídos a cada variável estão apresentados na Tabela 4.1.

Tabela 4.1 – Valores das correlações de Pearson com a variável dependente C-COV, percentual correspondente a cada variável de acordo com a soma dos valores da correlação e pesos calculados para cada variável.


Variável	Pearson*	Percentagem**	Peso
A-URB	0.925	22.92	0.2292
A-COR	0.708	17.54	0.1754
EFS	0.323	8.00	0.0800
EFC	0.476	11.79	0.1179
EFIC	0.238	5.90	0.0590
EFIT	0.115	2.85	0.0285
IMRS-V	0.393	9.74	0.0974
IMRS-CEL	0.339	8.40	0.0840
DV	0.519	12.86	0.1286
Total	4.036	100	1

*Valores significativos ao nível de 1% de probabilidade

**Percentagem do valor de correlação da variável em relação a soma de todos os valores

O $IVT_{SARS-CoV-2}$ obtido por meio do modelo de análise multicritério, variou de 1 a 8 para os 853 municípios de Minas Gerais. Os municípios que obtiveram um resultado de 1 foram os caracterizados como de menor risco de transmissão da doença. Por outro lado, aqueles que registraram valores mais altos de $IVT_{SARS-CoV-2}$, foram classificados como municípios com maior risco de transmissão da viral (Figura 4.2).


Figura 4.2 – Níveis do $IVT_{SARS-CoV-2}$ para os municípios de Minas Gerais.



Fonte: Elaborado pelos autores

O maior $IVT_{SARS-CoV-2}$ foi identificado em Belo Horizonte, capital situada na região central de Minas Gerais, com um valor de 8. O segundo maior índice foi observado em Uberlândia, localizada na região oeste do estado, com um $IVT_{SARS-CoV-2}$ de 6. Outros quatro municípios apresentaram índices iguais a 5: Uberaba, vizinho de Uberlândia; Contagem e Nova Lima, municípios limítrofes à capital estadual; e Juiz de Fora, situado na região sudeste de Minas Gerais (Figura 4.3). A distribuição desses índices evidenciou a concentração de municípios com elevada vulnerabilidade em áreas associadas a polos urbanos de destaque e regiões metropolitanas.

Figura 4.3 – Níveis do $IVT_{SARS-CoV-2}$ e microrregiões de maior vulnerabilidade no âmbito de Minas Gerais.



Fonte: Elaborado pelos autores.

Entre os 853 municípios de Minas Gerais, 31 destacaram-se por apresentarem os maiores níveis de vulnerabilidade à transmissibilidade do SARS-CoV-2. Além dos seis municípios previamente mencionados, com índices variando entre 5 e 8, outros 25 municípios atingiram um $IVT_{SARS-CoV-2}$ igual a 4, conforme detalhado na Tabela 4.2. Esses municípios estão distribuídos em diversas regiões do estado, refletindo a heterogeneidade da vulnerabilidade à COVID-19 em Minas Gerais.

Entre os 31 municípios que apresentaram os maiores valores de $IVT_{SARS-CoV-2}$, destacaram-se três localizados na Região Metropolitana de Belo Horizonte: Contagem, Betim e Nova Lima. Além disso, treze municípios, a exemplo de Belo Horizonte, foram identificados como sedes de superintendências regionais de saúde: Divinópolis, Governador Valadares, Juiz de Fora, Montes Claros, Passos, Patos de Minas, Ponte Nova, Pouso Alegre, Sete Lagoas, Teófilo Otoni, Uberaba, Uberlândia e Varginha. Por fim, Itabira, Ituiutaba e Unaí figuraram como sedes de gerências regionais de saúde (SES-MG, 2025c).

Tabela 4.2 – Municípios com os maiores valores de $IVT_{SARS-CoV-2}$ de acordo com o modelo proposto.

Código IBGE	Município	IVT	Código IBGE	Município	IVT
3106200	Belo Horizonte	8	3152501	Pouso Alegre	4
3170206	Uberlândia	6	3104007	Araxá	4
3170107	Uberaba	5	3134202	Ituiutaba	4
3118601	Contagem	5	3127701	Governador Valadares	4
3136702	Juiz de Fora	5	3127107	Frutal	4
3144805	Nova Lima	5	3148103	Patrocínio	4
3143302	Montes Claros	4	3147006	Paracatu	4
3148004	Patos de Minas	4	3131307	Ipatinga	4
3106705	Betim	4	3131703	Itabira	4
3170404	Unaí	4	3120904	Curvelo	4
3122306	Divinópolis	4	3147907	Passos	4
3103504	Araguari	4	3107406	Bom Despacho	4
3170701	Varginha	4	3126109	Formiga	4
3151800	Poços de Caldas	4	3168606	Teófilo Otoni	4
3167202	Sete Lagoas	4	3152105	Ponte Nova	4
3125101	Extrema	4	-	-	-

A performance do modelo, avaliada por meio da média dos valores de EQM obtidos em cada iteração da validação cruzada, se mostrou bastante satisfatória. Sendo que, o valor médio do EQM foi extremamente pequeno, aproximadamente $5,8331 \times 10^{-32}$.

4.4 DISCUSSÕES

A variável de maior peso na ADMC foi A-URB, contribuindo com 22,92% do peso do modelo. Essa variável está intrinsecamente ligada ao tamanho da população que a habita, pois o crescimento das áreas urbanas está diretamente relacionado ao aumento populacional (MARSHALL, 2007). O aumento da densidade de edificações e áreas construídas, resultante da expansão urbana, intensifica o risco de disseminação de doenças, uma vez que a proximidade física favorece a transmissão entre indivíduos (CHEN et al., 2024; YU et al., 2021). Ademais,

grandes centros urbanos ofertam maior gama de serviços e produtos oriundos do comércio e indústria e, com o maior dinamismo econômico, há um maior fluxo de pessoas de outras localidades regionais, nacionais e internacionais (DAVID et al., 2013; KNOWLES, 2012; LI; YANG, 2003; MARCONATO; PARRÉ; COELHO, 2021). Por fim, condições de vida marcadas pela superlotação e o acesso desigual aos serviços de saúde em centros urbanos, especialmente em comunidades de baixa renda, ampliam o risco de exposição ao vírus e dificultam a efetividade das medidas de controle da doença (CONNOLLY; KEIL; ALI, 2021; MUNSTER et al., 2018).

A segunda variável de maior importância para a ADMC foi A-COR, sendo o peso dessa variável correspondente a 17,54% do $IVT_{SARS-CoV-2}$. Inicialmente o aumento de casos de COVID-19 se deu por meio da difusão hierárquica e a difusão por contágio adquiriu maior relevância a partir do estabelecimento da transmissão local do vírus SARS-CoV-2 (BATELLA; MIYAZAKI, 2020; SOUZA; FERREIRA JÚNIOR, 2020). Nesse sentido, o deslocamento de indivíduos infectados pelo SARS-CoV-2 passou a exercer um papel crucial no aumento dos casos da doença (ALIDADI; SHARIFI, 2022; KEPHART et al., 2021; WANG et al., 2020b). Ademais, o deslocamento populacional por meio de transportes públicos revelou-se um fator relevante para a transmissibilidade viral, devido tanto à aglomeração de pessoas quanto ao tempo de exposição (CHANG et al., 2021; LI; MA; ZHANG, 2021).

Em áreas urbanas, a maior conectividade e densidade populacional tendem a facilitar a disseminação rápida de patógenos como o SARS-CoV-2, enquanto as áreas rurais, embora menos densas, podem apresentar vulnerabilidade devido à conectividade com centros urbanos. Adicionalmente, medidas de controle podem apresentar eficácia limitada em áreas urbanas em comparação com áreas rurais (WELLS et al., 2020). De maneira geral, a densidade populacional e as intensas interações sociais em centros urbanos contribuem significativamente para a rápida disseminação de patógenos, aumentando o risco de surtos e pandemias (BOTERMAN, 2023; PATIL et al., 2021).

Outra variável independente relacionada à mobilidade populacional é a densidade de veículos, com 12,86% do peso para a ADMC. Uso de automóveis acarreta na emissão de poluentes atmosféricos $PM_{2,5}$ e PM_{10} (ARTÍÑANO et al., 2004; BEDDOWS; HARRISON, 2021). A exposição aos particulados $PM_{2,5}$ e PM_{10} , que podem estar carreando diferentes tipos de patógenos, causam impactos negativos significativos ao sistema imunológico dos seres humanos por meio de danos ao sistema respiratório dos indivíduos expostos (ZORAN et al., 2020). Ademais, a variação da concentração de $PM_{2,5}$ pode ser um outro fator que contribui negativamente para a saúde dos indivíduos expostos aos poluentes, de forma que, períodos de

picos de concentração de $PM_{2,5}$ podem ser sucedidos por períodos de picos no número de mortes por consequência da COVID-19 (RENARD et al., 2023). Em suma, a poluição atmosférica vem sem sendo relacionada ao aumento da incidência de casos e de mortes por COVID-19 em diferentes regiões do mundo (BRAĞOSZEWSKA; MAINKA, 2022; GONÇALVES et al., 2023; JIANG; WU; GUAN, 2020; KHANIABADI et al., 2022; MEO; AL-KHLAIWI; ULLAH, 2021).

Dentre as variáveis relativas à ocupação profissional da população e suas relações com a alta transmissibilidade de COVID-19 destacaram-se as variáveis EFC e EFS, correspondendo respectivamente a 11,79 e 8% dos pesos para a ADMC. Dessa maneira, municípios com maior proporção populacional ocupando vagas no varejo e de serviços se mostraram mais susceptíveis à COVID-19. Ao se avaliar as características populacionais que se relacionam com maior número de casos da doença causada pelo vírus SARS-CoV-2, vários autores encontraram maior vulnerabilidade dentre trabalhadores ligados aos setores de comércio e serviços, destacando-se empregos nos segmentos de bares e restaurantes, transportes, movimentação de cargas e saúde (ANDERSEN et al., 2021; DE ANGELIS et al., 2021; GARNIER et al., 2021; YOSHIKAWA; KAWACHI, 2021).

Os subíndices IMRS-V e IMRS-CEL, corresponderam respectivamente a 9,74 e 8,40% dos pesos para a ADMC. Desta maneira, temos a condição de vulnerabilidades social sendo positivamente relacionada à maior incidência de COVID-19 (CIFUENTES et al., 2021; QUAN et al., 2021; YOSHIKAWA; KAWACHI, 2021). Assim como, a possibilidade de cidades com mais infraestruturas destinadas fins recreativos, terem promovido a aglomeração de pessoas em detrimento do distanciamento social (DE ANGELIS et al., 2021). Para além disso, no momento de registro dos casos de COVID-19 utilizados no presente trabalho (fevereiro de 2022) já havia uma certa tranquilidade e volta à normalidade por parte da população, devido ao fato do avanço das campanhas de vacinação (BUTANTAN, 2021). E ainda, não houve consideração por parte da sociedade de que a variante Ômicron, que estava em circulação no estado, possuía grande potencial de disseminação (BUTANTAN, 2022). Vale ressaltar que a “Emergência em Saúde Pública de Importância Nacional (ESPIN) em decorrência da infecção humana pelo novo coronavírus (2019-nCoV)” foi encerrado pela PORTARIA GM/MS Nº 913, DE 22 DE ABRIL DE 2022 e entrou em vigor 30 dias após sua publicação (BRASIL, 2022).

4.5 CONSIDERAÇÕES FINAIS

Este estudo avaliou a vulnerabilidade dos municípios de Minas Gerais à transmissão do SARS-CoV-2 utilizando o índice $IVT_{SARS-CoV-2}$, baseado no modelo de ADMC. O índice evidenciou o papel crucial de variáveis socioeconômicas e de infraestrutura urbana, como mobilidade, densidade de veículos, conectividade e ocupação profissional, na disseminação do vírus. Embora essas variáveis expliquem parte da dinâmica de transmissão, limitações como subnotificação de casos e ausência de fatores comportamentais afetam a precisão do modelo.

Apesar das limitações, como subnotificação de casos e ausência de variáveis comportamentais, o $IVT_{SARS-CoV-2}$ demonstra ser uma ferramenta apropriada para subsidiar políticas públicas, priorizar recursos e mitigar crises sanitárias. Além disso, o índice pode ser aplicado a outras doenças transmissíveis e adaptado a diferentes contextos regionais, provendo análises específicas e alinhadas às necessidades locais.

Os resultados destacam a importância de compreender as dinâmicas socioespaciais que influenciam a vulnerabilidade dos territórios, contribuindo para estratégias mais eficientes de enfrentamento de pandemias. Nossos resultados, de forma inovadora, mostram a necessidade de incluir corredores e conectividade urbana no contexto do planejamento territorial como estratégia de mitigação a eventos pandêmicos. Estudos futuros que explorem a inclusão de variáveis comportamentais e novas abordagens metodológicas podem aprimorar ainda mais as análises realizadas, aumentando sua aplicabilidade e precisão.

5 MODELAGEM ESPACIAL DA DISSEMINAÇÃO DA COVID-19 EM MINAS GERAIS: ANÁLISE DAS TRÊS PRIMEIRAS ONDAS E FATORES SOCIOECONÔMICOS⁴

RESUMO

Este estudo analisa a disseminação espacial da COVID-19 nos municípios de Minas Gerais durante os picos das três primeiras ondas da pandemia (julho de 2020, abril de 2021 e fevereiro de 2022), considerando fatores socioeconômicos e urbanos. A pesquisa emprega modelos de regressão espacial – Spatial Error Model (SEM), Spatial Autoregressive Model (SAR) e Spatial Autoregressive Moving Average Model (SARMA) – para avaliar a relação entre a incidência da doença e variáveis como densidade populacional, infraestrutura viária, tamanho da mancha urbana, setor econômico e indicadores sociais. Os dados foram obtidos da Secretaria de Estado de Saúde de Minas Gerais (SES-MG), da Fundação João Pinheiro (FJP) e de fontes geoespaciais, como MapBiomias e OpenStreetMap. Os testes estatísticos confirmaram dependência espacial significativa entre os municípios, reforçando a influência da conectividade territorial na propagação do vírus. Os resultados indicaram que, no início da pandemia, a densidade populacional e a mobilidade urbana foram determinantes para a transmissão. Posteriormente, a estrutura urbana e a infraestrutura viária ganharam maior relevância, refletindo mudanças no comportamento populacional e no avanço das políticas de mitigação. A análise revelou clusters espaciais persistentes de alta incidência, evidenciando que fatores estruturais influenciaram a propagação da doença. Além disso, municípios com melhor infraestrutura de cultura, esporte e lazer registraram menores taxas de infecção, sugerindo o papel desses fatores na redução da transmissão. A pesquisa reforça a importância da modelagem espacial na formulação de estratégias epidemiológicas e sugere que futuras investigações integrem o impacto da vacinação e medidas de controle em diferentes escalas geográficas.

Palavras-chave: Modelagem espacial; COVID-19; Fatores socioeconômicos; Regressão espacial.

ABSTRACT

This study analyzes the spatial dissemination of COVID-19 in the municipalities of Minas Gerais during the peaks of the first three waves of the pandemic (July 2020, April 2021, and February 2022), considering socioeconomic and urban factors. The research uses spatial regression models – Spatial Error Model (SEM), Spatial Autoregressive Model (SAR), and Spatial Autoregressive Moving Average Model (SARMA) – to assess the relationship between the incidence of the disease and variables such as population density, road infrastructure, size of the urban area, economic sector, and social indicators. The data were obtained from the Minas Gerais State Health Department (SES-MG), the João Pinheiro Foundation (FJP), and geospatial sources such as MapBiomias and OpenStreetMap. Statistical tests confirmed significant spatial dependence between municipalities, reinforcing the influence of territorial connectivity on the spread of the virus. The results indicated that, at the beginning of the pandemic, population density and urban mobility were decisive for transmission. Later, urban structure and road infrastructure gained greater relevance, reflecting changes in population behavior and the advancement of mitigation policies. The analysis revealed persistent spatial clusters of high incidences, evidencing that structural factor influenced the spread of the disease. In addition, municipalities with better cultural, sports, and leisure infrastructure recorded lower infection rates, suggesting the role of these factors in reducing transmission. The research reinforces the importance of spatial modeling in the formulation of epidemiological strategies and suggests that future investigations integrate the impact of vaccination and control measures at different geographic scales.

Keywords: Spatial modeling; COVID-19; Socioeconomic factors; Spatial regression.

⁴ Artigo de autoria de Matheus Luiz Jorge Cortez e Úrsula Ruchkys de Azevedo em preparação.

5.1 INTRODUÇÃO

A pandemia de COVID-19 evidenciou a forte relação entre fatores socioeconômicos, demográficos e urbanos e a propagação da doença, destacando como as características do território influenciam tanto a disseminação do vírus quanto seus impactos nas comunidades. Estudos anteriores demonstraram que variáveis como densidade populacional, condições de moradia e acesso a serviços de saúde desempenham um papel determinante na propagação do vírus e nas taxas de mortalidade (NASCIMENTO; CARVALHO; CARVALHO, 2024). Além disso, a estrutura urbana e a mobilidade populacional configuraram elementos-chave na velocidade de contágio, especialmente nos estágios iniciais da pandemia.

A interação entre o espaço urbano e a epidemiologia tem sido amplamente estudada a partir de abordagens espaciais, permitindo compreender padrões de transmissão de doenças infecciosas. No caso da COVID-19, fatores estruturais e socioeconômicos não apenas moldam a distribuição espacial dos casos, mas também influenciam as interações entre os municípios na disseminação do vírus. Nesse contexto, métodos estatísticos espaciais têm se mostrado ferramentas essenciais para identificar padrões geográficos de propagação da doença e analisar a influência de variáveis socioeconômicas e urbanas na transmissão.

Diante dessa perspectiva, este estudo investiga os padrões espaciais da disseminação da COVID-19 nos municípios de Minas Gerais durante os picos das três primeiras ondas da pandemia (julho de 2020, abril de 2021 e fevereiro de 2022). Para isso, são aplicados modelos de regressão espacial, incluindo o Spatial Error Model (SEM), o Spatial Autoregressive Model (SAR) e o Spatial Autoregressive Moving Average Model (SARMA), para avaliar a relação entre a incidência da doença e variáveis socioeconômicas e urbanas. Entre os fatores analisados, destacam-se o tamanho da mancha urbana, a área de corredores viários, a população, os empregos formais nos setores de serviços, comércio, indústria da construção e indústria de transformação, além de indicadores sociais, como o Índice Mineiro de Responsabilidade Social (IMRS) - vulnerabilidade e IMRS - cultura, esporte e lazer.

Com base nesse panorama, o estudo tem como objetivo principal analisar as relações entre os picos das três primeiras ondas de COVID-19 e variáveis socioeconômicas e urbanas dos municípios mineiros, utilizando modelos de regressão espacial. Os objetivos específicos são: (1) identificar a distribuição espacial dos novos casos mensais da doença nos períodos analisados; (2) examinar a associação entre o número de casos e variáveis urbanas e socioeconômicas, incluindo o tamanho da mancha urbana, a área de corredores viários, a população, os empregos formais nos setores de serviços, comércio, indústria da construção e

indústria de transformação, além dos indicadores sociais Índice Mineiro de Responsabilidade Social (IMRS) – vulnerabilidade e IMRS – cultura, esporte e lazer; (3) aplicar modelos de regressão espacial, especificamente o Spatial Error Model (SEM), o Spatial Autoregressive Model (SAR) e o Spatial Autoregressive Moving Average Model (SARMA), para avaliar a influência dessas variáveis na disseminação da COVID-19; e (4) comparar os resultados desses modelos para cada uma das três ondas da pandemia, identificando possíveis mudanças na influência das variáveis ao longo do tempo e padrões de dependência espacial.

A hipótese central do estudo sustenta que variáveis como alta densidade populacional, amplas áreas urbanizadas e elevados índices de vulnerabilidade social estejam positivamente associadas ao aumento de casos de COVID-19 durante os picos das três primeiras ondas da pandemia. Além disso, espera-se que os modelos de regressão espacial revelem padrões de dependência espacial significativos, indicando que municípios vizinhos influenciam mutuamente suas taxas de infecção. Também se considera que a influência dessas variáveis tenha se modificado ao longo do tempo, refletindo mudanças no comportamento populacional,

5.2 METODOLOGIA

A presente pesquisa utilizou métodos de análise espacial para avaliar a disseminação da COVID-19 nos municípios de Minas Gerais em três períodos distintos: julho de 2020, abril de 2021 e fevereiro de 2022 (MOURA et al., 2022). A abordagem baseia-se na modelagem estatística espacial, uma vez que a propagação de doenças infecciosas não ocorre de forma homogênea, mas sim estruturada espacialmente, sendo influenciada por fatores geográficos, socioeconômicos e urbanos. Dessa forma, a aplicação de modelos espaciais permite identificar padrões de distribuição da doença e entender como características locais e regionais influenciam sua disseminação.

5.2.1 Base de Dados e Pré-processamento

Os dados de COVID-19 em escala municipal foram obtidos da Secretaria de Estado de Saúde de Minas Gerais – SES-MG, enquanto os dados socioeconômicos foram extraídos da Fundação João Pinheiro – FJP (FJP, 2019b; SES-MG, 2025a). Para caracterizar a estrutura urbana, utilizou-se a base do MapBiomas, por meio da coleção 7.0, referente ao ano de 2021, a partir de arquivos raster que representam a área urbana mapeada (MAPBIOMAS, 2025). A infraestrutura viária foi modelada a partir da base de dados do OpenStreetMap – OSM (OSM,

2025b), adaptada para representar corredores viários relevantes para a mobilidade e conectividade dos municípios. Além disso, para a espacialização das variáveis, foi utilizado um arquivo vetorial tipo .SHP contendo a divisão territorial dos municípios mineiros, disponibilizado pelo Instituto Brasileiro de Geografia e Estatística – IBGE (IBGE, 2025b).

A Tabela 5.1 apresenta um resumo das variáveis explicativas utilizadas na modelagem. Todas as variáveis foram normalizadas para garantir comparabilidade e reduzir problemas de escala.

Tabela 5.1 – Variáveis explicativas utilizadas para modelagem

Sigla	Variável	Fonte
AU-N	Área urbana normalizada -2021	MapBiomias
AR-N	Área de rodovias normalizada - 2021	OpenStreetMaps
POP-N	População municipal normalizada- 2019	FJP
EFS	Empregos do setor de serviços (%) - 2019	FJP
EFC	Empregos do setor de comércio (%) - 2019	FJP
EFIC	Empregos do setor da indústria da construção (%) - 2019	FJP
EFIT	Empregos do setor da indústria de transformação (%) - 2019	FJP
DV	Densidade de veículos - 2019	FJP
IMRS-V	IMRS - Vulnerabilidade - 2018	FJP
IMRS-CEL	IMRS - Cultura, Esportes e Lazer - 2018	FJP

5.2.2 Desenvolvimento dos modelos

A modelagem espacial foi implementada no software R, utilizando pacotes especializados em análise de dados geoespaciais e econometria espacial. O pacote *sf* foi empregado para a manipulação de dados geográficos e a transformação de sistemas de coordenadas, enquanto o *spdep* permitiu a construção das matrizes de vizinhança e a realização de testes estatísticos espaciais, como o Moran's I. Para a estimação dos modelos SAR, SEM e SARMA utilizou-se o *spatialreg*, uma das ferramentas mais robustas para ajuste de modelos espaciais autoregressivos e de erro espacial (BIVAND et al., 2024, 2025; PEBESMA et al., 2024).

O pacote *MASS* foi utilizado para a seleção de variáveis com base no critério de informação de Akaike (AIC), garantindo a escolha do modelo mais simples e estatisticamente adequado (RIPLEY et al., 2025). Para visualização dos resultados, o *ggplot2* foi empregado na construção de mapas temáticos e gráficos de dispersão espacial, permitindo a interpretação intuitiva dos padrões espaciais da COVID-19 (WICKHAM et al., 2024).

5.2.3 Definição da Matriz de Vizinhaça

A estrutura espacial da dependência espacial entre os municípios foi modelada por meio de uma matriz de vizinhaça baseada no critério de rainha, que considera como vizinhos todos os municípios que compartilham uma borda ou vértice. Essa abordagem é amplamente utilizada na literatura de econometria espacial por capturar de forma abrangente as interações espaciais entre unidades territoriais adjacentes. Os pesos espaciais foram padronizados de modo que a soma das conexões de cada município fosse igual a 1, garantindo proporcionalidade nas relações espaciais (ANSELIN, 1988).

5.2.4 Testes de Dependência Espacial

Antes da aplicação dos modelos espaciais, foram realizados testes para verificar a presença de dependência espacial nos dados, assegurando a necessidade de uma abordagem espacial:

- Teste Global de Moran I: avalia a autocorrelação espacial global dos resíduos do modelo OLS, indicando se há padrões espaciais significativos (ANSELIN; REY, 1991; MORAN, 1950).
- Testes de Multiplicador de Lagrange (LMerr e LMlag): determinam se a modelagem espacial deve ser conduzida por meio da inclusão de defasagem espacial da variável dependente (SAR) ou da modelagem da dependência espacial nos erros (SEM) (ANSELIN; REY, 1991; BREUSCH; PAGAN, 1980).

5.2.5 Especificação dos Modelos

Foram ajustados o modelo de regressão múltipla e três modelos espaciais distintos para cada período analisado:

1. Modelo de Regressão OLS (Mínimos Quadrados Ordinários) (GRÉGOIRE, 2014): utilizado como referência para verificar a presença de autocorrelação espacial nos resíduos.
2. Modelo de Erro Espacial (SEM - Spatial Error Model): considera que a dependência espacial ocorre nos erros do modelo (ANSELIN, 1988).

3. Modelo de Defasagem Espacial (SAR - Spatial Autoregressive Model): assume que a variável dependente é influenciada diretamente pelos valores da mesma variável nos municípios vizinhos (ANSELIN, 1988).
4. Modelo SARMA (Spatial Autoregressive Moving Average): combina os efeitos do SAR e SEM, permitindo capturar simultaneamente as interações espaciais da variável dependente e dos erros (ANSELIN, 1988; KELLEY PACE; BARRY, 1997).

A seleção do modelo mais adequado para cada período foi baseada no Critério de Informação de Akaike (AIC), no teste espacial de Hausman e na log-verossimilhança.

5.2.6 Cálculo de Impactos Espaciais e Visualização dos Dados

Para os modelos SARMA, além dos coeficientes padronizados, foram estimados os impactos diretos, indiretos e totais das variáveis explicativas, permitindo a decomposição dos efeitos espaciais (LESAGE; PACE, 2009). Os modelos SEM foram testados a partir da aplicação do teste espacial de Hausman (KELLEY PACE; LESAGE, 2008). A interpretação desses impactos é fundamental para compreender a influência de variáveis socioeconômicas e urbanas na disseminação da COVID-19.


A visualização dos dados espaciais foi realizada por meio da construção de mapas temáticos e gráficos de dispersão de Moran I, permitindo identificar clusters espaciais e relações de dependência entre municípios. Para refinar essa análise, foi aplicado o Local Indicators of Spatial Association (LISA), que categoriza os municípios em clusters de alta ou baixa incidência da COVID-19, permitindo a detecção de hotspots e coldspots de transmissão (ANSELIN, 1995).

5.3 RESULTADOS E DISCUSSÕES

A análise da autocorrelação espacial global dos resíduos da regressão, por meio do índice de Moran I, revelou a presença significativa de padrões espaciais ao longo dos três períodos analisados. Em julho de 2020, o índice de Moran I foi 0.1138 ($p < 0.00000001993$), sugerindo que os resíduos do modelo apresentaram um padrão espacial não aleatório. Isso indica que a disseminação da COVID-19 esteve fortemente associada a fatores espaciais não capturados pelo modelo OLS. Em abril de 2021, a estatística aumentou para 0.1158 ($p < 0.000000009699$), reforçando a necessidade de modelagem espacial para capturar corretamente os efeitos da propagação do vírus. Em fevereiro de 2022, a estatística foi 0.1074 ($p <$


0.00000009261), mantendo-se estatisticamente significativa, mas com um leve enfraquecimento da dependência espacial em relação aos períodos anteriores (FIGURAS 5.1, 5.2 e 5.3). Esses resultados sugerem que, ao longo da pandemia, a influência espacial permaneceu relevante, mas pode ter sido modulada por fatores como campanhas de vacinação, medidas de controle e mudanças no comportamento populacional.

Figura 5.1 – Gráfico de dispersão de Moran I para os casos de COVID-19 em julho de 2020




Fonte: Elaborado pelos autores.

Figura 5.2 – Gráfico de dispersão de Moran I para os casos de COVID-19 em abril de 2021



Fonte: Elaborado pelos autores.

Figura 5.3 – Gráfico de dispersão de Moran I para os casos de COVID-19 em fevereiro de 2022




Fonte: Elaborado pelos autores.

5.3.1 Análise Local da Dependência Espacial: Identificação de Clusters

A aplicação do Local Indicators of Spatial Association (LISA) permitiu a identificação de clusters espaciais, destacando municípios onde a COVID-19 apresentou alta incidência em relação aos seus vizinhos. Essa abordagem complementa a análise do Global Moran I, detalhando onde a autocorrelação espacial é mais intensa. Os clusters Alto-Alto identificaram municípios com alta incidência da doença cercados por outros municípios igualmente impactados, funcionando como epicentros da transmissão ao longo dos três picos analisados. Os clusters Baixo-Baixo indicaram áreas de menor disseminação, reforçando a hipótese de que características estruturais e socioeconômicas locais exerceram influência sobre a propagação do vírus (FIGURAS 5.4, 5.5 e 5.6).


Os resultados do LISA indicam que, em julho de 2020, a disseminação inicial foi mais intensa nas regiões metropolitanas, onde a conectividade entre municípios favoreceu a circulação do vírus. Em abril de 2021, com o avanço da pandemia, os clusters Alto-Alto expandiram-se para cidades de médio porte, refletindo a interiorização da COVID-19. Em fevereiro de 2022, os padrões espaciais indicaram que a transmissão da COVID-19 permaneceu elevada em alguns clusters persistentes. Observou-se, ainda, o surgimento de novos clusters do tipo Alto-Alto no interior do estado, além do aumento na quantidade de clusters Baixo-Baixo.

Figura 5.4 – Padrões locais de autocorrelação espacial em julho de 2020




Fonte: Elaborado pelos autores.

Figura 5.5 – Padrões locais de autocorrelação espacial em abril de 2021



Fonte: Elaborado pelos autores.

Figura 5.6 – Padrões locais de autocorrelação espacial em fevereiro de 2022



Fonte: Elaborado pelos autores.

5.3.2 Modelagem Espacial e Comparação dos Modelos

A modelagem espacial aplicada neste estudo permitiu compreender os padrões de disseminação da COVID-19 nos municípios mineiros ao longo dos três primeiros grandes picos da pandemia: julho de 2020, abril de 2021 e fevereiro de 2022. Foram testados os modelos OLS, SEM, SAR e SARMA, exceto para julho de 2020, onde o modelo SAR não foi indicado pelo teste multiplicador de Lagrange (TABELA 5.2). A escolha do melhor modelo para cada período foi baseada nos critérios estatísticos de ajuste, como o critério de informação de Akaike (AIC) e a Log-verossimilhança, bem como na interpretação dos coeficientes e dos impactos espaciais. Como o AIC penaliza modelos mais complexos, um AIC menor indica um equilíbrio entre qualidade de ajuste e parcimônia. Já um maior valor para Log-verossimilhança (Log-Likelihood - logL), indica que o modelo conseguiu capturar melhor a estrutura dos dados observados (AKAIKE, 1974; CAVANAUGH; NEATH, 2019).

Tabela 5.2 – Teste multiplicador de Lagrange

Período	Teste	Estatística	Valor <i>p</i>	Conclusão
Julho de 2020	RSerr (Erro Espacial)	29.025	7.15E-08	Significativo
	RSlag (Defasagem Espacial)	1.9811	0.1593	Não Significativo
	SARMA (Erro + Defasagem)	39.791	2.29E-09	Muito Significativo
Abril de 2021	RSerr (Erro Espacial)	30.05	4.21E-08	Significativo
	RSlag (Defasagem Espacial)	121.37	2.20E-16	Muito Significativo
	SARMA (Erro + Defasagem)	183.89	2.20E-16	Muito Significativo
Fevereiro de 2022	LMerr (Erro Espacial)	25.845	3.70E-07	Significativo
	LMlag (Defasagem Espacial)	22.918	1.69E-06	Significativo
	SARMA	75.283	2.20E-16	Muito Significativo

Para julho de 2020, o modelo SEM (AIC = 11166; logL = -5576) apresentou um menor valor de AIC, indicando melhor ajuste do que o OLS (AIC = 11187). Entretanto, o teste de Hausman (chi-quadrado = 22.912; $p = 0.0003509$) confirmou que os coeficientes do modelo SEM diferem significativamente dos do modelo OLS, reforçando a inadequação do modelo OLS para capturar a dependência espacial dos dados e, ao mesmo tempo, indicando que o modelo SEM pode não capturar toda a estrutura espacial da disseminação da COVID-19. O modelo SARMA (AIC = 11161; logL = -5572) demonstrou ser o mais adequado, capturando tanto a dependência na variável dependente quanto nos erros (TABELAS 5.3, 5.4 e 5.5).

Tabela 5.3 – Modelo OLS para variável dependente casos de COVID -19 em julho de 2020

	Estimativa	Erro padrão	Valor <i>t</i>	Valor <i>p</i>	VIF
(Intercepto)	18.08	17.55	1.03	0.3033	-
POP-N	13007.71	272.89	47.67	2.00E-16	3.54
EFIC	13.25	5.86	2.26	2.40E-02	1.08
DV	0.24	0.04	5.80	9.14E-09	3.32
IMRS-CEL	-114.79	32.52	-3.53	0.0004	1.15
Residual standard error: 169.7 on 848 degrees of freedom					
Multiple R-squared: 0.9193, Adjusted R-squared: 0.9189					
F-statistic: 2415 on 4 and 848 DF, p-value: < 2.2e-16					

Tabela 5.4 – Modelo SEM para variável dependente casos de COVID -19 em julho de 2020

Variável	Estimativa	Erro padrão	Valor z	Valor p
(Intercepto)	13.08	18.17	0.72	0.4717
POP-N	12976.60	269.73	48.11	2.20E-16
DV	0.26	0.04	6.51	7.65E-11
IMRS-CEL	-102.43	32.97	-3.11	0.0019
EFIC	11.63	5.79	2.01	0.0445
Lambda: 0.22145, LR test value: 22.042, p-value: 0.0000026673				
Asymptotic standard error: 0.050575				
z-value: 4.3786, p-value: 0.000011944				
Wald statistic: 19.172, p-value: 0.000011944				
Hausman test = 22.912, df = 5, p-value = 0.0003509				

Tabela 5.5 – Modelo SARMA para variável dependente casos de COVID -19 em julho de 2020

Variável	Estimativa	Erro padrão	Valor z	Valor p
(Intercepto)	19.05	18.35	1.04	0.2993
POP-N	13026.35	268.49	48.52	2.20E-16
DV	0.26	0.04	6.45	1.09E-10
IMRS-CEL	-101.11	32.89	-3.07	0.0021
EFIC	13.45	5.80	2.32	0.0204
Rho: -0.053822				
Asymptotic standard error: 0.019623				
z-value: -2.7427, p-value: 0.0060929				
Lambda: 0.2535				
Asymptotic standard error: 0.052543				
z-value: 4.8246, p-value: 0.0000014025				

Em abril de 2021, o modelo SAR obteve o melhor ajuste (AIC = 11712; logL = -5848) em relação aos modelos SEM (AIC = 11828; logL = -5906) e o OLS (AIC = 11855). O teste de Hausman (chi-quadrado = 19.382; p = 0.000623) indicou que os coeficientes do SEM diferem significativamente dos do OLS, reforçando a inadequação dos modelos para capturar toda a estrutura espacial da disseminação da COVID-19. O modelo SARMA (AIC = 11688; logL = -5835) novamente obteve o melhor desempenho (TABELAS 5.6, 5.7, 5.8 e 5.9).

Tabela 5.6 – Modelo OLS para variável dependente casos de COVID -19 em abril de 2021

	Estimativa	Erro padrão	Valor <i>t</i>	Valor <i>p</i>	VIF
(Intercept)	-56.46	28.83	-1.96	0.0505	-
Pop-N	29976.07	498.62	60.12	2.00E-16	5.40
AR-N	348.53	125.68	2.77	5.67E-03	1.91
EFS	8.52	2.30	3.70	2.29E-04	1.13
DV	0.50547	0.06691	7.554	1.09E-13	3.98
IMRS-CEL	-117.80	49.86	-2.36	0.0184	1.23

Residual standard error: 251 on 847 degrees of freedom
Multiple R-squared: 0.966, Adjusted R-squared: 0.9658
F-statistic: 4809 on 5 and 847 DF, p-value: < 2.2e-16

Tabela 5.7 – Modelo SEM para variável dependente casos de COVID -19 em abril de 2021

Variável	Estimativa	Erro padrão	Valor <i>z</i>	Valor <i>p</i>
(Intercepto)	-51.67	30.37	-1.70	0.0888
POP-N	30754.94	497.39	61.83	2.20E-16
DV	0.51	0.06	7.90	2.89E-15
EFS	8.31	2.29	3.64	0.0003
AR-N	273.74	131.91	2.08	0.0380
IMRS-CEL	-121.57	51.16	-2.38	0.0175

Lambda: 0.27512, LR test value: 28.671, p-value: 0.000000085793
Asymptotic standard error: 0.049022
z-value: 5.6123, p-value: 0.000000019965
Wald statistic: 31.498, p-value: 0.000000019965
Hausman test = 133.23, df = 6, p-value < 2.2e-16

Tabela 5.8 – Modelo SAR para variável dependente casos de COVID -19 em abril de 2021

Variável	Estimativa	Erro padrão	Valor <i>z</i>	Valor <i>p</i>
(Intercepto)	-26.75	26.49	-1.01	0.3126
POP-N	31118.81	465.14	66.90	2.20E-16
DV	0.43	0.06	7.03	2.07E-12
EFS	9.08	2.11	4.31	1.63E-05
AR-N	232.42	115.37	2.01	0.0440
IMRS-CEL	-81.64	45.66	-1.79	0.0738

Rho: -0.13736, LR test value: 144.63, p-value: < 2.22e-16
Asymptotic standard error: 0.010745
z-value: -12.784, p-value: < 2.22e-16
Wald statistic: 163.44, p-value: < 2.22e-16

Tabela 5.9 – Modelo SARMA para variável dependente casos de COVID -19 em abril de 2021

Variável	Estimativa	Erro padrão	Valor z	Valor p
(Intercepto)	-10.59	27.84	-0.38	0.7037
POP-N	31198.98	458.99	67.97	2.20E-16
DV	0.45	0.06	7.55	4.40E-14
EFS	8.19	2.10	3.90	9.67E-05
AR-N	154.52	120.84	1.28	0.2010
IMRS-CEL	-81.44	46.84	-1.74	0.0820
Rho: -0.14228				
Asymptotic standard error: 0.011379				
z-value: -12.504, p-value: < 2.22e-16				
Lambda: 0.23102				
Asymptotic standard error: 0.051263				
z-value: 4.5066, p-value: 0.0000065875				

Para fevereiro de 2022, após a detecção de colinearidade entre POP-N e AU-N, a variável POP-N foi excluída da modelagem. Dentre os modelos OLS (AIC = 13394), SEM (AIC = 13376; logL = -6681) e SAR (AIC = 13372; logL = -6679), o modelo SAR foi o de melhor desempenho. Entretanto, o melhor ajustamento foi apresentado pelo modelo SARMA (AIC = 13339; logL = -6661). Novamente, o teste de Hausman (chi-quadrado = 50.2; p = 0.000000001261) reforçou que os coeficientes do SEM diferem significativamente dos do OLS, indicando que o modelo SEM pode não capturar toda a estrutura espacial da disseminação da COVID-19 (TABELAS 5.10, 5.11, 5.12 e 5.13).

Tabela 5.10 – Modelo OLS para variável dependente casos de COVID -19 em fevereiro de 2022

	Estimativa	Erro padrão	Valor t	Valor p	VIF
(Intercepto)	23.91	65.08	0.37	0.7135	-
AU-N	30730.40	764.27	40.21	2.00E-16	5.34
AR-N	2316.82	332.94	6.96	6.87E-12	2.03
DV	-0.75	0.12	-6.35	3.50E-10	1.43
IMRS-CEL	-315.12	123.57	-2.55	0.0109	4.01
Residual standard error: 619.1 on 848 degrees of freedom					
Multiple R-squared: 0.8749, Adjusted R-squared: 0.8744					
F-statistic: 1483 on 4 and 848 DF, p-value: < 2.2e-16					

Tabela 5.11 – Modelo SEM para variável dependente casos de COVID -19 em fevereiro de 2022

Variável	Estimativa	Erro padrão	Valor z	Valor p
(Intercepto)	16.76	66.97	0.25	0.8024
AU-N	31744.23	774.71	40.98	2.20E-16
AR-N	2197.29	347.95	6.32	2.70E-10
DV	-0.79	0.11	-6.87	6.41E-12
IMRS-CEL	-308.08	126.53	-2.43	0.0149
Lambda: 0.21227, LR test value: 19.984, p-value: 0.0000078097				
Asymptotic standard error: 0.050827				
z-value: 4.1763, p-value: 0.000029632				
Wald statistic: 17.441, p-value: 0.000029632				
Hausman test = 50.2, df = 5, p-value = 0.00000001261				

Tabela 5.12 – Modelo SAR para variável dependente casos de COVID -19 em fevereiro de 2022

Variável	Estimativa	Erro padrão	Valor z	Valor p
(Intercepto)	92.04	65.38	1.41	0.1592
AU-N	31315.21	766.03	40.88	2.20E-16
AR-N	2292.79	327.31	7.00	2.47E-12
DV	-0.77	0.12	-6.58	4.72E-11
IMRS-CEL	-315.25	121.38	-2.60	0.0094
Rho: -0.0976, LR test value: 24.201, p-value: 0.00000086795				
Asymptotic standard error: 0.019781				
z-value: -4.934, p-value: 0.0000008056				
Wald statistic: 24.344, p-value: 0.0000008056				

Tabela 5.13 – Modelo SARMA para variável dependente casos de COVID -19 em fevereiro de 2022

Variável	Estimativa	Erro padrão	Valor z	Valor p
(Intercepto)	123.25	68.56	1.80	0.0722
AU-N	32170.88	760.10	42.32	2.20E-16
AR-N	2024.72	344.75	5.87	4.28E-09
DV	-0.79	0.11	-7.09	1.38E-12
IMRS-CEL	-289.98	124.39	-2.33	0.0198
Rho: -0.1354				
Asymptotic standard error: 0.022315				
z-value: -6.0674, p-value: 0.000000013001				
Lambda: 0.27542				
Asymptotic standard error: 0.052487				
z-value: 5.2475, p-value: 0.00000015421				

5.3.3 Testes de impactos dos modelos SARMA

Os modelos SARMA foram os mais significativos para compreensão da COVID-19 nos três períodos analisados. Ademais, os impactos dos modelos SARMA revelaram padrões

distintos na disseminação da COVID-19 em Minas Gerais, refletindo a evolução da pandemia e as mudanças nos fatores determinantes da transmissão.

No primeiro pico, em julho de 2020, a população (POP-N) foi o principal fator associado ao aumento dos casos, reforçando que municípios mais populosos enfrentaram maior propagação do vírus (TABELA 5.14). Além disso, essa variável indicou por meio de seu impacto indireto negativo, que a influenciou na redução da transmissão viral em municípios vizinhos dos grandes centros urbanos. Esta relação pode estar associada com a estrutura de saúde do estado de Minas Gerais, pois, devido às questões de alocação de recursos, há uma centralização em superintendências e gerências regionais de saúde (SES-MG, 2025c). Desta forma, pode ter havido o deslocamento de pessoas com COVID-19 para os grandes centros populacionais e, assim, ter aliviado a situação nos municípios de menor porte.

Já a densidade de veículos (DV) apresentou impacto direto positivo significativo, indicando que a mobilidade urbana favoreceu a disseminação da doença e, de maneira similar, o setor da construção civil (EFIC) também influenciou positivamente a transmissão dentro dos municípios, o que pode indicar que houve continuidade das atividades laborais presenciais durante esse período.

A interpretação dos impactos do IMRS-CEL sugere um comportamento espacial diferenciado na disseminação da COVID-19. O impacto direto negativo indica que municípios com maior infraestrutura de cultura, esporte e lazer registraram menor número de casos, reforçando a hipótese de que espaços recreativos para atividades ao ar livre e um maior nível cultural contribuíram para reduzir a exposição ao vírus e mitigar a transmissão viral. Por outro lado, o impacto indireto positivo sugere que, embora esses municípios tenham se beneficiado da infraestrutura disponível, seus municípios vizinhos podem ter experimentado um efeito oposto, possivelmente devido a deslocamentos populacionais. Esse resultado pode indicar que a presença de infraestrutura de lazer em determinados municípios levou a um fluxo de pessoas de áreas vizinhas para acessar esses espaços, aumentando a exposição ao vírus em regiões próximas. A significância estatística de ambos os impactos confirma que essa variável desempenhou um papel relevante na dinâmica espacial da pandemia, reforçando a necessidade de considerar efeitos diretos e indiretos ao interpretar modelos espaciais de transmissão de doenças.

Tabela 5.14 – Impactos do modelo SARMA para o período de julho de 2020

Variável	Impacto direto	Impacto indireto	Impacto total	Valores <i>p</i> simulados		
				Direto	Indireto	Total
POP-N	13032.81	-671.76	12361.06	2.22E-16	0.0061	2.22E-16
DV	0.26	-0.01	0.24	4.87E-10	0.0112	7.46E-10
IMRS-CEL	-101.16	5.21	-95.95	0.0009	0.0341	0.0009
EFIC	13.45	-0.69	12.76	0.0235	0.0976	0.0231

No segundo pico, em abril de 2021, os padrões de impacto permaneceram semelhantes, mas com intensidades diferentes (TABELA 5.15). A população continuou sendo o fator predominante, consolidando-se como a variável mais importante para explicar a transmissão do vírus. A DV manteve-se significativa, porém com um efeito ligeiramente reduzido em comparação ao primeiro período, sugerindo que algumas medidas de restrição de circulação adotadas nesse intervalo podem ter atenuado a influência desse fator. O setor de serviços (EFS) tornou-se um elemento relevante, com impacto positivo, indicando que municípios com maior concentração de empregos formais no setor terciário enfrentaram maiores taxas de infecção, possivelmente devido à reabertura econômica e ao aumento das interações sociais. A área de rodovias (AR-N) e a IMRS-CEL não apresentaram impactos estatisticamente significativos nesse período, o que pode estar relacionado a um endurecimento das medidas de proteção não farmacêuticas impostas pelos governantes.

Tabela 5.15 – Impactos do modelo SARMA para o período de abril de 2021

Variável	Impacto direto	Impacto indireto	Impacto total	Valores <i>p</i> simulados		
				Direto	Indireto	Total
POP-N	31304.83	-3991.99	27312.84	2.22E-16	2.22E-16	2.22E-16
DV	0.45	-0.06	0.39	5.55E-15	1.21E-12	9.77E-15
EFS	8.21	-1.05	7.17	4.09E-05	5.88E-05	4.40E-05
AR-N	155.05	-19.77	135.28	0.1915	0.1919	0.1919
IMRS-CEL	-81.72	10.42	-71.30	0.0673	0.0714	0.0672

No terceiro pico, em fevereiro de 2022, houve uma alteração nos fatores determinantes da transmissão (TABELA 5.16). A variável POP-N foi substituída por área urbana (AU-N) devido à colinearidade, demonstrando que, à medida que a pandemia evoluiu, a extensão da mancha urbana tornou-se um fator mais relevante que a densidade populacional na disseminação do vírus.

Além disso, a DV apresentou um impacto negativo, em oposição aos períodos anteriores, sugerindo que mudanças nos padrões de deslocamento e a maior adesão ao transporte individual contribuíram para reduzir a transmissão.

O IMRS-CEL manteve seu efeito protetor para o município com alto valor para o índice, verificado por meio do impacto direto negativo e, com efeito contrário para os municípios com vizinhos, observado por meio do impacto indireto positivo. Sendo que, ambos os impactos foram significativos.

A infraestrutura viária (AR-N) se tornou mais influente sobre a disseminação da COVID-19 em fevereiro de 2022. Esse crescimento sugere que, na fase mais tardia da pandemia, a conectividade viária interna dos municípios se importante na propagação do vírus, possivelmente devido à retomada das atividades econômicas.

Tabela 5.16 – Impactos do modelo SARMA para o período de fevereiro de 2022

Variável	Impacto direto	Impacto indireto	Impacto total	Valores <i>p</i> simulados		
				Direto	Indireto	Total
AU-N	32269.86	-3935.35	28334.51	2.22E-16	4.41E-11	2.22E-16
AR-N	2030.95	-247.68	1783.27	1.12E-08	1.16E-05	1.77E-08
DV	-0.79	0.10	-0.69	8.14E-12	1.13E-06	1.69E-11
IMRS-CEL	-290.87	35.47	-255.40	0.0196	0.0265	0.0201

A evolução das variantes do SARS-CoV-2 influenciou significativamente a disseminação da COVID-19 em Minas Gerais, com diferentes cepas predominando em cada fase da pandemia. Variantes menos transmissíveis marcaram a primeira onda, enquanto cepas mais contagiosas e com maior escape imunológico, como Alpha, Gamma e Delta, predominaram na segunda. Na terceira onda, destacou-se a rápida disseminação da variante Ômicron. Essas mudanças genéticas afetaram os padrões espaço-temporais da transmissão e a eficácia das medidas de controle (MARKOV et al., 2023).

5.4 CONCLUSÃO

Este estudo analisou a disseminação espacial da COVID-19 em Minas Gerais ao longo dos três primeiros picos da pandemia, utilizando modelos espaciais para avaliar a influência de variáveis urbanas e socioeconômicas. Os resultados demonstraram que a propagação do vírus não ocorreu de maneira homogênea, mas sim estruturada espacialmente, com municípios influenciando diretamente seus vizinhos. A modelagem espacial revelou padrões distintos ao longo do tempo: nos estágios iniciais da pandemia, a densidade populacional teve um papel predominante na disseminação da doença, enquanto, nas fases mais avançadas, a organização do espaço urbano e a conectividade viária tornaram-se fatores determinantes.

A persistência de clusters espaciais de transmissão indicou que a COVID-19 não afetou todas as regiões da mesma forma, reforçando a influência direta do fator locacional na propagação da doença. A infraestrutura viária e o setor de serviços se mostraram variáveis críticas, sugerindo que medidas de controle devem considerar não apenas as condições sanitárias locais, mas também a interdependência entre cidades e a dinâmica de deslocamento populacional. Além disso, verificou-se que municípios com maior infraestrutura de cultura, esporte e lazer apresentaram menor incidência de casos, possivelmente devido à disponibilidade de espaços abertos que facilitaram o distanciamento social.

A principal contribuição desta pesquisa está na aplicação da modelagem espacial como ferramenta para a análise epidemiológica, demonstrando que métodos estatísticos espaciais podem fornecer informações mais precisas e realistas para a formulação de estratégias de contenção de pandemias. Ao incorporar a dimensão espacial, foi possível superar limitações dos modelos tradicionais, evidenciando que a propagação do vírus não se limitou a características individuais dos municípios, mas também foi fortemente influenciada pela conectividade entre eles.

A comparação entre os períodos analisados mostra que os principais fatores determinantes da transmissão da COVID-19 se modificaram ao longo do tempo, refletindo tanto a evolução da pandemia quanto o impacto de medidas de controle e mudanças no comportamento da população. A população e a estrutura urbana se consolidaram como os fatores mais relevantes, enquanto a mobilidade urbana teve um impacto variável, passando de positiva nos primeiros períodos para negativa no último, indicando uma adaptação nos padrões de deslocamento. A infraestrutura de lazer demonstrou um efeito protetor constante, sugerindo que municípios com maior disponibilidade de espaços ao ar livre registraram menos casos ao longo da pandemia. Essas análises reforçam a necessidade de considerar a dinâmica espacial da transmissão para a formulação de estratégias de controle mais eficazes em futuras crises sanitárias.

Embora o modelo SARMA tenha apresentado o melhor ajuste, futuras pesquisas podem explorar abordagens híbridas que integrem aprendizado de máquina, possibilitando previsões mais refinadas dos padrões de disseminação. Além disso, sugere-se a ampliação do escopo desta pesquisa para incluir o impacto da vacinação, das políticas de isolamento social e das mudanças no comportamento populacional em diferentes escalas geográficas. Estudos comparativos entre estados brasileiros ou mesmo entre países podem aprofundar a compreensão sobre como fatores estruturais e socioeconômicos modulam a propagação de doenças infecciosas.

6 CONCLUSÃO GERAL

Esta tese teve como objetivo investigar os fatores socioeconômicos determinantes da vulnerabilidade dos municípios mineiros à disseminação da COVID-19, desenvolvendo metodologias integradas para mapear essa vulnerabilidade e subsidiar políticas públicas mais eficazes. A pesquisa foi estruturada em três eixos complementares: uma análise bibliométrica da produção científica sobre a relação entre COVID-19 e fatores socioeconômicos, a análise da autocorrelação espacial entre casos e mortes pela doença e características socioeconômicas municipais, e a construção de um Índice de Vulnerabilidade à Transmissibilidade do SARS-CoV-2 (IVTSARS-CoV-2) para os municípios de Minas Gerais.

Os resultados reforçam que a disseminação da COVID-19 não ocorreu de forma homogênea, mas seguiu padrões espaciais bem definidos, fortemente influenciados por fatores estruturais e dinâmicas socioeconômicas. A pandemia não apenas evidenciou desigualdades socioespaciais preexistentes, como também revelou a necessidade de políticas públicas territorialmente diferenciadas, que levem em consideração as particularidades locais e regionais na gestão de crises sanitárias. O primeiro eixo da pesquisa, por meio da análise bibliométrica, revelou que, apesar do vasto interesse acadêmico inicial sobre os impactos socioeconômicos da COVID-19, houve uma desaceleração na taxa de crescimento das publicações em nível global e nacional à medida que a pandemia foi controlada. No entanto, Minas Gerais apresentou um crescimento anual positivo na produção científica sobre o tema, o que sugere um interesse crescente por análises tardias e estudos locais voltados para a compreensão dos impactos prolongados da pandemia. Esse cenário revela um dilema importante da ciência: enquanto as investigações iniciais priorizam o enfrentamento imediato da crise, análises mais aprofundadas tendem a surgir apenas posteriormente, quando a atenção global já se deslocou para outros temas.

A análise da autocorrelação espacial da COVID-19 nos municípios mineiros, referente ao segundo eixo da pesquisa, demonstrou que a transmissão e os óbitos pela doença seguiram padrões espaciais associados à densidade populacional, à estrutura urbana e aos indicadores de desenvolvimento humano. Municípios com maior taxa de envelhecimento, menor Índice de Desenvolvimento Humano e maior vulnerabilidade social registraram taxas mais elevadas de mortalidade, enquanto a infraestrutura urbana e o acesso a serviços de saúde foram determinantes na mitigação dos impactos da pandemia.

O terceiro eixo da pesquisa envolveu a construção do IVT_{SARS-CoV-2}, que revelou que os maiores níveis de vulnerabilidade à transmissão estavam concentrados nos grandes centros

urbanos e regiões metropolitanas, particularmente em Belo Horizonte, Uberlândia, Uberaba, Contagem, Nova Lima e Juiz de Fora. A expansão das áreas urbanas, a mobilidade populacional e a conectividade regional foram os principais determinantes da disseminação do vírus, indicando que a pandemia se espalhou de forma hierárquica, seguindo os fluxos econômicos e sociais do território. Municípios de médio porte, que atuam como sede de superintendências e gerências regionais de saúde e polos econômicos, também apresentaram altos níveis de vulnerabilidade, ressaltando o papel dessas cidades na estrutura de circulação do vírus. Esses achados reforçam que políticas de enfrentamento a pandemias não devem ser formuladas apenas em nível nacional ou estadual, mas precisam considerar redes intermunicipais e fluxos regionais de transmissão.

Além disso, a ocupação profissional também teve impacto significativo na vulnerabilidade à COVID-19. Municípios com maior participação de trabalhadores nos setores de comércio e serviços apresentaram maior incidência da doença, evidenciando que condições laborais precárias podem amplificar a exposição ao vírus. Essa relação reforça a importância de políticas públicas que garantam proteção sanitária adequada para trabalhadores essenciais, especialmente em momentos de crise sanitária.

Ademais, a comparação entre os períodos analisados mostrou que os principais fatores determinantes da transmissão da COVID-19 variaram ao longo do tempo, refletindo a dinâmica da pandemia, os impactos das medidas de controle e as alterações no comportamento da população.

Apesar das contribuições desta pesquisa, algumas limitações devem ser consideradas, especialmente a falta de dados detalhados. O acesso a informações como a localização exata (por CEP) de pacientes internados e óbitos permitiria uma análise espacial mais precisa, identificando hotspots e padrões intraurbanos de transmissão. No entanto, esses dados não foram disponibilizados pelos municípios, limitando a profundidade das análises. A tentativa de parceria com a Prefeitura de Belo Horizonte para obter informações mais detalhadas resultou apenas no acesso aos dados públicos da Secretaria de Estado da Saúde de Minas Gerais. Essa limitação reflete um desafio na pesquisa epidemiológica: a dificuldade de acesso a bases mais completas restringe o potencial analítico e a formulação de políticas públicas baseadas em evidências.

Além da questão da disponibilidade de dados, outras limitações devem ser consideradas. A subnotificação de casos e óbitos (RIBEIRO; BERNARDES, 2020) impactou a precisão das análises, subestimando possivelmente a real magnitude da pandemia em Minas Gerais. Outro ponto que merece atenção é a influência de fatores comportamentais e culturais, como adesão

ao distanciamento social, ao uso de máscaras e a vacinação, que não foram incluídos no modelo por falta de dados sistemáticos. Essas dimensões são essenciais para compreender a dinâmica de transmissão de doenças infecciosas e devem ser exploradas em futuras investigações.

Além disso, os impactos socioeconômicos de longo prazo da pandemia não foram contemplados nesse estudo e permanecem uma lacuna. A COVID-19 gerou efeitos que vão além da esfera sanitária, afetando a empregabilidade, a saúde mental e a qualidade de vida da população. Estudos adicionais são necessários para avaliar essas repercussões, especialmente em grupos mais vulneráveis.

Apesar dos desafios e limitações, esta pesquisa desenvolveu adaptações metodológicas inovadoras para a análise da pandemia de COVID-19 no contexto mineiro. A aplicação das metodologias adotadas permitiu a identificação de fatores relevantes para a transmissão e mortalidade da doença em nível estadual e pode servir de base para o enfrentamento de futuras crises sanitárias decorrentes de doenças virais na população de Minas Gerais.

Uma perspectiva promissora para pesquisas futuras é a validação do IVT_{SARS-CoV-2} para outras doenças transmissíveis, como a influenza, ampliando sua aplicabilidade como ferramenta preditiva para crises sanitárias. A adaptação do índice a diferentes contextos epidemiológicos pode fortalecer a capacidade de resposta governamental, permitindo o planejamento antecipado de medidas de mitigação e alocação de recursos em emergências de saúde pública.

Os achados desta tese dialogam diretamente com os Objetivos de Desenvolvimento Sustentável (ODS) da ONU, especialmente aqueles relacionados à saúde pública, desigualdades sociais e planejamento urbano sustentável. O ODS 3 – Saúde e Bem-Estar é contemplado ao aprofundar a compreensão dos determinantes sociais da saúde e propor ferramentas que auxiliam na formulação de políticas para mitigação de pandemias. O ODS 10 – Redução das Desigualdades é reforçado ao demonstrar que a pandemia afetou desproporcionalmente as populações mais vulneráveis, evidenciando a necessidade de maior equidade no acesso à saúde e na proteção social. Já o ODS 11 – Cidades e Comunidades Sustentáveis relaciona-se com os achados da pesquisa ao destacar a influência da infraestrutura urbana e da mobilidade populacional na disseminação do vírus, sublinhando a importância do planejamento territorial para tornar as cidades mais resilientes a crises sanitárias.

De maneira mais ampla, esta tese reforça que pandemias não devem ser tratadas apenas como desafios biomédicos, mas como fenômenos profundamente interligados às dinâmicas sociais, econômicas e territoriais. A integração de metodologias espaciais e multicritério, conforme desenvolvido nesta pesquisa, representa um avanço metodológico significativo e um

passo essencial para a formulação de estratégias mais eficazes na gestão de emergências sanitárias. Em um mundo cada vez mais interconectado, a ciência tem um papel central na mitigação dos impactos das pandemias, garantindo que políticas de prevenção, resposta e recuperação sejam direcionadas para onde são mais necessárias, evitando que populações vulneráveis sejam sistematicamente negligenciadas em futuros cenários de crise.

REFERÊNCIAS

- AHMED, F. et al. Why inequality could spread COVID-19. **The Lancet. Public Health**, v. 5, n. 5, p. e240, maio 2020.
- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v. 19, n. 6, p. 716–723, dez. 1974.
- ALI, U. et al. A data-driven approach for multi-scale GIS-based building energy modeling for analysis, planning and support decision making. **Applied Energy**, v. 279, p. 115834, 1 dez. 2020.
- ALIDADADI, M.; SHARIFI, A. Effects of the built environment and human factors on the spread of COVID-19: A systematic literature review. **Science of The Total Environment**, v. 850, p. 158056, 1 dez. 2022.
- ALVES, A. et al. Uncovering COVID-19 infection determinants in Portugal: towards an evidence-based spatial susceptibility index to support epidemiological containment policies. **International Journal of Health Geographics**, v. 22, n. 1, p. 8, 6 abr. 2023.
- ANDERSEN, L. M. et al. Analyzing the spatial determinants of local Covid-19 transmission in the United States. **Science of The Total Environment**, v. 754, p. 142396, 1 fev. 2021.
- ANSELIN, L. **Spatial Econometrics: Methods and Models**. [s.l.] Springer Science & Business Media, 1988.
- ANSELIN, L. Local Indicators of Spatial Association—LISA. **Geographical Analysis**, v. 27, n. 2, p. 93–115, 1995.
- ANSELIN, L. et al. Simple diagnostic tests for spatial dependence. **Regional science and urban economics**, v. 26, n. 1, p. 77–104, 1996.
- ANSELIN, L.; REY, S. Properties of Tests for Spatial Dependence in Linear Regression Models. **Geographical Analysis**, v. 23, n. 2, p. 112–131, 1991.
- ANSELIN, L.; SYABRI, I.; KHO, Y. GeoDa: An Introduction to Spatial Data Analysis. Em: FISCHER, M. M.; GETIS, A. (Eds.). **Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications**. Berlin, Heidelberg: Springer, 2010. p. 73–89.
- ARAÚJO, I. S. DE; BRANDÃO, V. B. G. TRABALHO E RENDA NO CONTEXTO DA PANDEMIA DE COVID-19 NO BRASIL. **Revista Prâksis**, v. 2, p. 96–111, 3 maio 2021.
- ARLOT, S.; CELISSE, A. A survey of cross-validation procedures for model selection. **Statistics Surveys**, v. 4, n. none, p. 40–79, jan. 2010.
- ARTÍÑANO, B. et al. Influence of traffic on the PM10 and PM2.5 urban aerosol fractions in Madrid (Spain). **Science of The Total Environment, Highway and Urban Pollution**. v. 334–335, p. 111–123, 1 dez. 2004.

ASTAIZA-GÓMEZ, J. **Lagrange Multiplier Tests in Applied Research**. Rochester, NY, 12 mar. 2020. Disponível em: <<https://papers.ssrn.com/abstract=3669884>>. Acesso em: 3 fev. 2023

ATCHISON, C. et al. Early perceptions and behavioural responses during the COVID-19 pandemic: a cross-sectional survey of UK adults. **BMJ Open**, v. 11, n. 1, p. e043577, 1 jan. 2021.

BAENA-DÍEZ, J. M. et al. Impact of COVID-19 outbreak by income: hitting hardest the most deprived. **Journal of Public Health**, v. 42, n. 4, p. 698–703, 23 nov. 2020.

BAMBRA, C. et al. The COVID-19 pandemic and health inequalities. **J Epidemiol Community Health**, v. 74, n. 11, p. 964–968, 1 nov. 2020.

BATELLA, W.; MIYAZAKI, V. K. RELAÇÕES ENTRE REDE URBANA E COVID-19 EM MINAS GERAIS. **Hygeia - Revista Brasileira de Geografia Médica e da Saúde**, p. 102–110, 18 jun. 2020.

BAYODE, T. et al. Spatial variability of COVID-19 and its risk factors in Nigeria: A spatial regression method. **Applied Geography**, v. 138, p. 102621, 1 jan. 2022.

BEDDOWS, D. C. S.; HARRISON, R. M. PM10 and PM2.5 emission factors for non-exhaust particles from road vehicles: Dependence upon vehicle mass and implications for battery electric vehicles. **Atmospheric Environment**, v. 244, p. 117886, 1 jan. 2021.

BENITA, F.; GASCA-SANCHEZ, F. The main factors influencing COVID-19 spread and deaths in Mexico: A comparison between phases I and II. **Applied Geography**, v. 134, p. 102523, 1 set. 2021.

BISHOP, C. M.; NASRABADI, N. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006. v. 4

BIVAND, R. et al. **spatialreg: Spatial Regression Analysis**. , 2 dez. 2024. Disponível em: <<https://cran.r-project.org/web/packages/spatialreg/index.html>>. Acesso em: 10 mar. 2025

BIVAND, R. et al. **spdep: Spatial Dependence: Weighting Schemes, Statistics**. , 20 jan. 2025. Disponível em: <<https://cran.r-project.org/web/packages/spdep/index.html>>. Acesso em: 10 mar. 2025

BMC PH. **BMC Public Health**. Disponível em: <<https://bmcpublikealth.biomedcentral.com/>>. Acesso em: 12 fev. 2025.

BMJ. **About - BMJ Open**. Disponível em: <<https://bmjopen.bmj.com/pages/about>>. Acesso em: 12 fev. 2025.

BONACCORSI, G. et al. Economic and social consequences of human mobility restrictions under COVID-19. **Proceedings of the National Academy of Sciences**, v. 117, n. 27, p. 15530–15535, 7 jul. 2020.

BORJAS, G. J. **Demographic Determinants of Testing Incidence and COVID-19 Infections in New York City Neighborhoods**. : Working Paper Series. National Bureau of

Economic Research, , abr. 2020. Disponível em: <<https://www.nber.org/papers/w26952>>. Acesso em: 3 fev. 2025

BOTERMAN, W. Population density and SARS-CoV-2 pandemic: Comparing the geography of different waves in the Netherlands. **Urban Studies**, v. 60, n. 8, p. 1377–1402, 1 jun. 2023.

BRĄGOSZEWSKA, E.; MAINKA, A. Impact of Different Air Pollutants (PM10, PM2.5, NO2, and Bacterial Aerosols) on COVID-19 Cases in Gliwice, Southern Poland. **International Journal of Environmental Research and Public Health**, v. 19, n. 21, p. 14181, jan. 2022.

BRASIL. **Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). Brasília, DF: Diário Oficial da União**, 2018.

BRASIL. **PORTARIA Nº 913, DE 22 DE ABRIL DE 2022**. Disponível em: <https://www.planalto.gov.br/ccivil_03/portaria/prt/portaria-913-22-ms.htm>. Acesso em: 3 jan. 2025.

BREUSCH, T. S.; PAGAN, A. R. The Lagrange Multiplier Test and its Applications to Model Specification in Econometrics. **The Review of Economic Studies**, v. 47, n. 1, p. 239–253, 1 jan. 1980.

BROWNE, M. W. Cross-Validation Methods. **Journal of Mathematical Psychology**, v. 44, n. 1, p. 108–132, 1 mar. 2000.

BUTANTAN, I. **Retrospectiva 2021: segundo ano da pandemia é marcado pelo avanço da vacinação contra Covid-19 no Brasil**. Disponível em: <<https://butantan.gov.br/noticias/retrospectiva-2021-segundo-ano-da-pandemia-e-marcado-pelo-avanco-da-vacinacao-contr-covid-19-no-brasil>>. Acesso em: 5 set. 2023.

BUTANTAN, I. **Seis fatos sobre a ômicron, a variante mais transmissível da Covid-19**. Disponível em: <<https://butantan.gov.br/noticias/seis-fatos-sobre-a-omicron-a-variante-mais-transmissivel-da-covid-19>>. Acesso em: 5 ago. 2023.

CAMPOS, I. S. et al. A Vulnerability Analysis for the Management of and Response to the COVID-19 Epidemic in the Second Most Populous State in Brazil. **Frontiers in Public Health**, v. 9, 2021.

CAPODEFERRO, M. W.; SMIDERLE, J. J. The Brazilian sanitation sector's response to COVID-19. **Revista de Administração Pública**, v. 54, p. 1022–1036, 28 ago. 2020.

CAVANAUGH, J. E.; NEATH, A. A. The Akaike information criterion: Background, derivation, properties, application, interpretation, and refinements. **WIREs Computational Statistics**, v. 11, n. 3, p. e1460, 2019.

CERQUEIRA, EUGÊNIA et al. PANORAMA DA COVID- 19 NO ESTADO DE MINAS. Em: **PANORAMA DA COVID-19 NO BRASIL**. 1ª ed. Curitiba: Editora CRV, 2022. v. 1p. 253–260.

CHANG, S. et al. Mobility network models of COVID-19 explain inequities and inform reopening. **Nature**, v. 589, n. 7840, p. 82–87, jan. 2021.

CHEN, L. et al. Long-term variations of urban–Rural disparities in infectious disease burden of over 8.44 million children, adolescents, and youth in China from 2013 to 2021: An observational study. **PLOS Medicine**, v. 21, n. 4, p. e1004374, 12 abr. 2024.

CHI, G.; ZHU, J. Spatial Regression Models for Demographic Analysis. **Population Research and Policy Review**, v. 27, n. 1, p. 17–42, 1 fev. 2008.

CIFUENTES, M. P. et al. Socioeconomic inequalities associated with mortality for COVID-19 in Colombia: a cohort nationwide study. **J Epidemiol Community Health**, v. 75, n. 7, p. 610–615, 1 jul. 2021.

CONNOLLY, C.; KEIL, R.; ALI, S. H. Extended urbanisation and the spatialities of infectious disease: Demographic change, infrastructure and governance. **Urban Studies**, v. 58, n. 2, p. 245–263, 1 fev. 2021.

CORTEZ, M. L. J. et al. WHAT ROLE DO SOCIAL VARIABLES AND HEALTH PLAY IN THE SPREAD OF COVID-19 IN THE STATE OF MINAS GERAIS – BRAZIL? **Caderno de Geografia**, v. 33, n. 72, p. 317–317, 3 abr. 2023.

COSTA, M. A. (EDITOR); MARGUTI, B. O. (EDITOR). Atlas da vulnerabilidade social nos municípios brasileiros. <http://www.ipea.gov.br>, 2015.

COURA-VITAL, W. et al. Spatiotemporal dynamics and risk estimates of COVID-19 epidemic in Minas Gerais State: analysis of an expanding process. **Revista do Instituto de Medicina Tropical de São Paulo**, v. 63, 24 mar. 2021.

CSC. **Passo a passo - Revista Ciência & Saúde Coletiva**. Disponível em: <<https://cienciaesaudecoletiva.com.br/passa-a-passo>>. Acesso em: 12 fev. 2025.

CSP. **Sobre a Revista | Cadernos de Saúde Pública**. Disponível em: <<https://cadernos.ensp.fiocruz.br/ojs/index.php/csp/about>>. Acesso em: 12 fev. 2025.

DAVID, Q. et al. Is bigger better? Economic performances of European cities, 1960–2009. **Cities**, v. 35, p. 237–254, 1 dez. 2013.

DE ALMEIDA, A. T. et al. A systematic literature review of multicriteria and multi-objective models applied in risk management. **IMA Journal of Management Mathematics**, v. 28, n. 2, p. 153–184, 1 abr. 2017.

DE ANGELIS, E. et al. COVID-19 incidence and mortality in Lombardy, Italy: An ecological study on the role of air pollution, meteorological factors, demographic and socioeconomic variables. **Environmental Research**, v. 195, p. 110777, 1 abr. 2021.

DE LAROCHELAMBERT, Q. et al. Covid-19 Mortality: A Matter of Vulnerability Among Nations Facing Limited Margins of Adaptation. **Frontiers in Public Health**, v. 8, 2020.

DE LUCENA, T. M. C. et al. Mechanism of inflammatory response in associated comorbidities in COVID-19. **Diabetes & Metabolic Syndrome: Clinical Research & Reviews**, v. 14, n. 4, p. 597–600, 1 jul. 2020.

DOM, N. C. et al. Application of geographical information system-based analytical hierarchy process as a tool for dengue risk assessment. **Asian Pacific Journal of Tropical Disease**, v. 6, n. 12, p. 928–935, 1 dez. 2016.

EJAZ, H. et al. COVID-19 and comorbidities: Deleterious impact on infected patients. **Journal of Infection and Public Health**, v. 13, n. 12, p. 1833–1839, 1 dez. 2020.

FAO, I. **The State of Food Security and Nutrition in the World 2021**.

FJP. **Fundação João Pinheiro - FJP**. , 2019a. Disponível em: <<http://fjp.mg.gov.br/>>. Acesso em: 6 fev. 2023

FJP. **Fundação João Pinheiro**. Disponível em: <<https://fjp.mg.gov.br/a-fjp/>>. Acesso em: 3 mar. 2025b.

FOX, J. et al. **car: Companion to Applied Regression**. , 27 set. 2024. Disponível em: <<https://cran.r-project.org/web/packages/car/index.html>>. Acesso em: 17 abr. 2025

FRONTIERS. **Frontiers in Public Health | About**. Disponível em: <<https://www.frontiersin.org/journals/public-health/about#about-scope>>. Acesso em: 12 fev. 2025.

GARNIER, R. et al. Socioeconomic Disparities in Social Distancing During the COVID-19 Pandemic in the United States: Observational Study. **Journal of Medical Internet Research**, v. 23, n. 1, p. e24591, 22 jan. 2021.

GELFAND, A. E. et al. Illustration of Bayesian Inference in Normal Data Models Using Gibbs Sampling. **Journal of the American Statistical Association**, v. 85, n. 412, p. 972–985, 1 dez. 1990.

GENTILINI, U. Social Protection and Jobs Responses to COVID-19 : A Real-Time Review of Country Measures (April 3, 2020) | Policy Commons. 2020.

Geografia de Minas Gerais. Disponível em: <<https://www.mg.gov.br/pagina/geografia>>. Acesso em: 6 fev. 2023.

GOLDMAN, N. Social Inequalities in Health. **Annals of the New York Academy of Sciences**, v. 954, n. 1, p. 118–139, 2001.

GONÇALVES, K. DOS S. et al. The potential impact of PM on the covid-19 crisis in the Brazilian Amazon region. **Rev. Saúde Pública**, v. 57, 14 set. 2023.

GRÉGOIRE, G. Multiple Linear Regression. **European Astronomical Society Publications Series**, v. 66, p. 45–72, jan. 2014.

GREKOUSIS, G.; WANG, R.; LIU, Y. Mapping the geodemographics of racial, economic, health, and COVID-19 deaths inequalities in the conterminous US. **Applied Geography**, v. 135, p. 102558, 1 out. 2021.

HAWKINS, R. B.; CHARLES, E. J.; MEHAFFEY, J. H. Socio-economic status and COVID-19-related cases and fatalities. **Public Health**, v. 189, p. 129–134, 1 dez. 2020.

HENNING, A. et al. Socio-spatial influences on the prevalence of COVID-19 in central Pennsylvania. **Spatial and Spatio-Temporal Epidemiology**, v. 37, p. 100411, jun. 2021.

HUI, D. S. et al. The continuing 2019-nCoV epidemic threat of novel coronaviruses to global health — The latest 2019 novel coronavirus outbreak in Wuhan, China. **International Journal of Infectious Diseases**, v. 91, p. 264–266, 1 fev. 2020.

IBGE. **Minas Gerais | Cidades e Estados | IBGE**. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/mg/>>. Acesso em: 3 jan. 2025a.

IBGE. **Instituto Brasileiro de Geografia e Estatística - Geociências - Downloads**. Disponível em: <<https://www.ibge.gov.br/geociencias/downloads-geociencias.html>>. Acesso em: 10 mar. 2025b.

IBGE | **Cidades@ | Minas Gerais | Panorama**. Disponível em: <<https://cidades.ibge.gov.br/brasil/mg/panorama>>. Acesso em: 6 fev. 2023.

IJERPH. **International Journal of Environmental Research and Public Health**. Disponível em: <<https://www.mdpi.com/journal/ijerph/about>>. Acesso em: 12 fev. 2025.

Ipeadata. Disponível em: <<http://www.ipeadata.gov.br/Default.aspx>>. Acesso em: 6 fev. 2023.

JAMA. **For Authors | JAMA Network Open | JAMA Network**. Disponível em: <<https://jamanetwork.com/journals/jamanetworkopen/pages/for-authors>>. Acesso em: 12 fev. 2025.

JIANG, Y.; WU, X.-J.; GUAN, Y.-J. Effect of ambient air pollutants and meteorological variables on COVID-19 incidence. **Infection Control & Hospital Epidemiology**, v. 41, n. 9, p. 1011–1015, set. 2020.

JREHD. **Journal of Racial and Ethnic Health Disparities**. Disponível em: <<https://link.springer.com/journal/40615/journal/40615>>. Acesso em: 12 fev. 2025.

KARMAKAR, M.; LANTZ, P. M.; TIPIRNENI, R. Association of Social and Demographic Factors With COVID-19 Incidence and Death Rates in the US. **JAMA Network Open**, v. 4, n. 1, p. e2036462, 29 jan. 2021.

KELLEY PACE, R.; BARRY, R. Sparse spatial autoregressions. **Statistics & Probability Letters**, v. 33, n. 3, p. 291–297, 5 maio 1997.

KELLEY PACE, R.; LESAGE, J. P. A spatial Hausman test. **Economics Letters**, v. 101, n. 3, p. 282–284, 1 dez. 2008.

KEPHART, J. L. et al. The effect of population mobility on COVID-19 incidence in 314 Latin American cities: a longitudinal ecological study with mobile phone location data. **The Lancet Digital Health**, v. 3, n. 11, p. e716–e722, 1 nov. 2021.

KHALATBARI-SOLTANI, S. et al. Importance of collecting data on socioeconomic determinants from the early stage of the COVID-19 outbreak onwards. **J Epidemiol Community Health**, v. 74, n. 8, p. 620–623, 1 ago. 2020a.

KHALATBARI-SOLTANI, S. et al. Importance of collecting data on socioeconomic determinants from the early stage of the COVID-19 outbreak onwards. **J Epidemiol Community Health**, v. 74, n. 8, p. 620–623, 1 ago. 2020b.

KHANIABADI, Y. O. et al. COVID-19 Outbreak Related to PM10, PM2.5, Air Temperature and Relative Humidity in Ahvaz, Iran. **Dr. Sulaiman Al Habib Medical Journal**, v. 4, n. 4, p. 182–195, 1 dez. 2022.

KNOWLES, R. D. Transit Oriented Development in Copenhagen, Denmark: from the Finger Plan to Ørestad. **Journal of Transport Geography**, Special Section on Rail Transit Systems and High Speed Rail. v. 22, p. 251–261, 1 maio 2012.

KOEHL, A. Urban transport and COVID-19: challenges and prospects in low- and middle-income countries. **Cities & Health**, v. 5, n. sup1, p. S185–S190, 21 jul. 2021.

KWOK, C. Y. T. et al. Spatial analysis of the impact of urban geometry and socio-demographic characteristics on COVID-19, a study in Hong Kong. **Science of The Total Environment**, v. 764, p. 144455, 10 abr. 2021.

LANZIAUX, É. et al. Covid-19 and vit-d: Disease mortality negatively correlates with sunlight exposure. **Spatial and Spatio-temporal Epidemiology**, v. 35, p. 100362, 1 nov. 2020.

LESAGE, J. P. Bayesian Estimation of Spatial Autoregressive Models. **International Regional Science Review**, v. 20, n. 1–2, p. 113–129, 1 abr. 1997.

LESAGE, J.; PACE, R. K. **Introduction to Spatial Econometrics**. New York: Chapman and Hall/CRC, 2009.

LI, J. Z.; YANG, D. C. Guangdong: China's Economic Powerhouse — The Past, the Present and the Future. Em: BUI, T. X. et al. (Eds.). **China's Economic Powerhouse: Reform in Guangdong Province**. London: Palgrave Macmillan UK, 2003. p. 208–230.

LI, S.; MA, S.; ZHANG, J. Association of built environment attributes with the spread of COVID-19 at its initial stage in China. **Sustainable Cities and Society**, v. 67, p. 102752, 1 abr. 2021.

LI, X. et al. Application of the analytic hierarchy approach to the risk assessment of Zika virus disease transmission in Guangdong Province, China. **BMC Infectious Diseases**, v. 17, n. 1, p. 65, 13 jan. 2017.

LIU, K. et al. Clinical features of COVID-19 in elderly patients: A comparison with young and middle-aged patients. **Journal of Infection**, v. 80, n. 6, p. e14–e18, 1 jun. 2020.

MACCARO, A. et al. Pandemic Preparedness: A Scoping Review of Best and Worst Practices from COVID-19. **Healthcare**, v. 11, n. 18, p. 2572, 18 set. 2023.

MACKENBACH, J. P. et al. Socioeconomic Inequalities in Health in 22 European Countries. **New England Journal of Medicine**, v. 358, n. 23, p. 2468–2481, 5 jun. 2008.

MAPBIOMAS. **MapBiomass Brasil**. Disponível em: <<https://brasil.mapbiomas.org/>>. Acesso em: 3 jan. 2025.

MARCONATO, M.; PARRÉ, J. L.; COELHO, M. H. Dinâmica financeira dos municípios brasileiros. **Revista de Administração Pública**, v. 55, p. 378–394, 5 maio 2021.

MARKOV, P. V. et al. The evolution of SARS-CoV-2. **Nature Reviews Microbiology**, v. 21, n. 6, p. 361–379, jun. 2023.

MAROKO, A. R.; NASH, D.; PAVILONIS, B. T. COVID-19 and Inequity: a Comparative Spatial Analysis of New York City and Chicago Hot Spots. **Journal of Urban Health**, v. 97, n. 4, p. 461–470, 1 ago. 2020.

MARSHALL, J. D. Urban Land Area and Population Growth: A New Scaling Relationship for Metropolitan Expansion. **Urban Studies**, v. 44, n. 10, p. 1889–1904, 1 set. 2007.

MATTHEW, O. J.; ELUDOYIN, A. O.; OLUWADIYA, K. S. Spatio-temporal variations in COVID-19 in relation to the global climate distribution and fluctuations. **Spatial and Spatio-temporal Epidemiology**, v. 37, p. 100417, 1 jun. 2021.

MEFTHAHI, G. H. et al. The possible pathophysiology mechanism of cytokine storm in elderly adults with COVID-19 infection: the contribution of “inflamm-aging”. **Inflammation Research**, v. 69, n. 9, p. 825–839, 1 set. 2020.

MENA, G. E. et al. Socioeconomic status determines COVID-19 incidence and related mortality in Santiago, Chile. **Science**, v. 372, n. 6545, p. eabg5298, 28 maio 2021.

MEO, S. A.; AL-KHLAIWI, T.; ULLAH, C. H. Effect of ambient air pollutants PM_{2.5} and PM₁₀ on COVID-19 incidence and mortality: observational study. **European Review for Medical and Pharmacological Sciences**, v. 25, n. 23, p. 7553–7564, dez. 2021.

MINGHINI, M.; SARRETTA, A.; NAPOLITANO, M. OpenStreetMap Contribution to Local Data Ecosystems in COVID-19 Times: Experiences and Reflections from the Italian Case. **Data**, v. 7, n. 4, p. 39, abr. 2022.

MINISTÉRIO DA SAÚDE. **Coronavírus Brasil**. Disponível em: <<https://covid.saude.gov.br/>>. Acesso em: 2 mar. 2025.

MISHRA, S. V.; GAYEN, A.; HAQUE, S. M. COVID-19 and urban vulnerability in India. **Habitat International**, v. 103, p. 102230, 1 set. 2020.

MOONEY, P. et al. OpenStreetMap Data Use Cases During the Early Months of the COVID-19 Pandemic. Em: **COVID-19 Pandemic, Geospatial Information, and Community Resilience**. [s.l.] CRC Press, 2021.

MORAN, P. A. P. Notes on Continuous Stochastic Phenomena. **Biometrika**, v. 37, n. 1/2, p. 17–23, 1950.

MOURA, E. C. et al. Covid-19: evolução temporal e imunização nas três ondas epidemiológicas, Brasil, 2020–2022. **Rev. Saúde Pública**, v. 56, 18 nov. 2022.

MUNSTER, V. J. et al. Outbreaks in a Rapidly Changing Central Africa — Lessons from Ebola. **New England Journal of Medicine**, v. 379, n. 13, p. 1198–1201, 27 set. 2018.

NASCIMENTO, É. S. DO; CARVALHO, F. DE M.; CARVALHO, E. G. Relação entre fatores socioeconômicos e a pandemia da covid-19. **Saúde e Sociedade**, v. 33, p. e220248pt, 15 mar. 2024.

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, 1 jun. 2020.

ONU. **Sustainable Development Goal 3: Saúde e Bem-Estar | As Nações Unidas no Brasil**. Disponível em: <<https://brasil.un.org/pt-br/sdgs/3>>. Acesso em: 3 jan. 2025.

ORELLANA, J. D. Y. et al. Excesso de mortes durante a pandemia de COVID-19: subnotificação e desigualdades regionais no Brasil. **Cadernos de Saúde Pública**, v. 37, p. e00259120, 5 fev. 2021.

ORONCE, C. I. A. et al. Association Between State-Level Income Inequality and COVID-19 Cases and Mortality in the USA. **Journal of General Internal Medicine**, v. 35, n. 9, p. 2791–2793, 1 set. 2020.

OSM. **OpenStreetMap Data Extracts**. Disponível em: <<https://download.geofabrik.de/>>. Acesso em: 3 jan. 2025a.

OSM. **OpenStreetMap**. Disponível em: <<https://www.openstreetmap.org/>>. Acesso em: 3 jan. 2025b.

PATEL, J. A. et al. Poverty, inequality and COVID-19: the forgotten vulnerable. **Public Health**, v. 183, p. 110–111, jun. 2020.

PATIL, R. et al. Assessing the interplay between travel patterns and SARS-CoV-2 outbreak in realistic urban setting. **Applied Network Science**, v. 6, n. 1, p. 1–19, dez. 2021.

PEBESMA, E. et al. **sf: Simple Features for R**, 5 nov. 2024. Disponível em: <<https://cran.r-project.org/web/packages/sf/index.html>>. Acesso em: 10 mar. 2025

PEDREGOSA, F. et al. scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PINTO, D. G. (COORDENAÇÃO); COSTA, M. A. (COORDENAÇÃO); MARQUES, M. L. DE A. (COORDENAÇÃO). O Índice de Desenvolvimento Humano Municipal brasileiro. **www.ipea.gov.br**, dez. 2013.

PLOS ONE. **Journal Information | PLOS ONE**. Disponível em: <<https://journals.plos.org/plosone/s/journal-information#loc-scope>>. Acesso em: 12 fev. 2025.

PRADO, M. F. DO et al. Análise da subnotificação de COVID-19 no Brasil. **Revista Brasileira de Terapia Intensiva**, v. 32, p. 224–228, 24 jun. 2020.

QUAN, D. et al. Impact of Race and Socioeconomic Status on Outcomes in Patients Hospitalized with COVID-19. **Journal of General Internal Medicine**, v. 36, n. 5, p. 1302–1309, 1 maio 2021.

R Core Team. **Project R: language and environment for statistical computing**, 2021.

RBE. **Revista Brasileira de Epidemiologia**. Disponível em:
<<https://www.scielo.br/journal/rbepid/about/>>. Acesso em: 12 fev. 2025.

RENARD, J.-B. et al. Temporal Evolution of PM2.5 Levels and COVID-19 Mortality in Europe for the 2020–2022 Period. **Atmosphere**, v. 14, n. 8, p. 1222, ago. 2023.

RIBEIRO, L.; BERNARDES, A. **Atualização da estimativa de subnotificação em casos de hospitalização por Síndrome Respiratória Aguda e confirmados por infecção por COVID-19 no Brasil e estimativa para Minas Gerais**. Belo Horizonte: Centro de Desenvolvimento e Planejamento Regional (Cedeplar/UFMG), 2020. Disponível em:
<<https://ufmg.br/comunicacao/noticias/estudo-da-face>>. Acesso em: 15 nov. 2024.

RIPLEY, B. et al. **MASS: Support Functions and Datasets for Venables and Ripley's MASS**. , 28 fev. 2025. Disponível em: <<https://cran.r-project.org/web/packages/MASS/index.html>>. Acesso em: 10 mar. 2025

RSP. **About RSP - Revista de Saúde Pública**. Disponível em:
<<https://rsp.fsp.usp.br/revista/?lang=en>>. Acesso em: 12 fev. 2025.

RSPH. **Public Health**. Disponível em: <<https://www.sciencedirect.com/journal/public-health>>. Acesso em: 12 fev. 2025.

SANGIORGIO, V.; PARISI, F. A multicriteria approach for risk assessment of Covid-19 in urban district lockdown. **Safety Science**, v. 130, p. 104862, 1 out. 2020.

SANNIGRAHI, S. et al. Examining the association between socio-demographic composition and COVID-19 fatalities in the European region using spatial regression approach. **Sustainable Cities and Society**, v. 62, p. 102418, 1 nov. 2020.

SANTOS, H. L. P. C. DOS et al. Gastos públicos com internações hospitalares para tratamento da covid-19 no Brasil em 2020. **Rev. Saúde Pública**, v. 55, 4 ago. 2021.

SANYAOLU, A. et al. Comorbidity and its Impact on Patients with COVID-19. **SN Comprehensive Clinical Medicine**, v. 2, n. 8, p. 1069–1076, 1 ago. 2020.

SCIENTIFIC REPORTS. **Guide to referees | Scientific Reports**. Disponível em:
<<https://www.nature.com/srep/guide-to-referees>>. Acesso em: 12 fev. 2025.

SECRETARIA DE ESTADO DE SAÚDE DE MINAS GERAIS. **DADOS ABERTOS CORONAVÍRUS**. Disponível em: <<https://coronavirus.saude.mg.gov.br/dadosabertos>>. Acesso em: 6 fev. 2023.

SES-MG. **Boletim Epidemiológico Coronavírus**. Disponível em:
<<https://coronavirus.saude.mg.gov.br/boletim>>. Acesso em: 16 fev. 2023.

SES-MG. **Painéis Vigilância Epidemiológica. COVID - Monitoramento**. Disponível em:
<<https://app.powerbi.com/view?r=eyJrIjoieZjg2ZDY2MWEtMDIxZC00NTk0LTg4OTQtMDk1YjYzNDZlNTNiIiwidCI6Ijg3ZTRkYTJiLTgyZGYtNDhmNi05MTU3LTk5YzNjYTYwMGRmMiIsImMiOiR9>>. Acesso em: 2 mar. 2025a.

SES-MG. **Dados Abertos Coronavírus**. Disponível em:
<<https://coronavirus.saude.mg.gov.br/dadosabertos>>. Acesso em: 3 jan. 2025b.

SES-MG. **Superintendências Regionais de Saúde (SRS) e Gerências Regionais de Saúde (GRS)**. Disponível em: <<https://www.saude.mg.gov.br/sobre/institucional/superintendencias-regionais-de-saude-e-gerencias-regionais-de-saude>>. Acesso em: 3 jan. 2025c.

SINHASHTHITA, W.; JEARANAITANAKIJ, K. **Improving KNN Algorithm Based on Weighted Attributes by Pearson Correlation Coefficient and PSO Fine Tuning**. 2020 - 5th International Conference on Information Technology (InCIT). **Anais...** Em: 2020 - 5TH INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY (INCIT). out. 2020.

SIQUEIRA, C. A. DOS S. et al. COVID-19 no Brasil: tendências, desafios e perspectivas após 18 meses de pandemia. **Revista Panamericana de Salud Pública**, v. 46, p. e74, 14 abr. 2023.

SOARES-FILHO, B. S.; COUTINHO CERQUEIRA, G.; LOPES PENNACHIN, C. **dinamica—a stochastic cellular automata model designed to simulate the landscape dynamics in an Amazonian colonization frontier**. **Ecological Modelling**, v. 154, n. 3, p. 217–235, 1 set. 2002.

SOUZA, M. V. M. DE; FERREIRA JÚNIOR, D. B. Rede urbana, interações espaciais e a geografia da saúde: análise da trajetória da Covid-19 no estado do Pará. **Espaço e Economia. Revista brasileira de geografia econômica**, n. 18, 21 abr. 2020.

SUSTAINABILITY. **MDPI - Sustainability**. Disponível em: <<https://www.mdpi.com/journal/sustainability>>. Acesso em: 12 fev. 2025.

TELLER, J. Urban density and Covid-19: towards an adaptive approach. **Buildings & Cities**, v. 2, n. 1, p. 150–165, 2021.

THOMPSON, B. Stepwise Regression and Stepwise Discriminant Analysis Need Not Apply here: A Guidelines Editorial. **Educational and Psychological Measurement**, v. 55, n. 4, p. 525–534, 1 ago. 1995.

VACCINES. **Vaccines**. Disponível em: <<https://www.mdpi.com/journal/vaccines/about>>. Acesso em: 12 fev. 2025.

VON SEIDLEIN, L. et al. Crowding has consequences: Prevention and management of COVID-19 in informal urban settlements. **Building and Environment**, v. 188, p. 107472, 15 jan. 2021.

WANG, B. et al. Does comorbidity increase the risk of patients with COVID-19: evidence from meta-analysis. **Aging (Albany NY)**, v. 12, n. 7, p. 6049–6057, 8 abr. 2020a.

WANG, B. et al. Airborne particulate matter, population mobility and COVID-19: a multi-city study in China. **BMC Public Health**, v. 20, n. 1, p. 1585, 21 out. 2020b.

WANG, S. et al. Mobile monitoring of urban air quality at high spatial resolution by low-cost sensors: impacts of COVID-19 pandemic lockdown. **Atmospheric Chemistry and Physics**, v. 21, n. 9, p. 7199–7215, 11 maio 2021.

WANG, T. et al. Comorbidities and multi-organ injuries in the treatment of COVID-19. **The Lancet**, v. 395, n. 10228, p. e52, 21 mar. 2020c.

WELLS, K. et al. Disease control across urban–rural gradients. **Journal of The Royal Society Interface**, v. 17, n. 173, p. 20200775, 9 dez. 2020.

WHO. **WHO Director-General’s opening remarks at the media briefing on COVID-19 - 11 March 2020**. Disponível em: <<https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>>. Acesso em: 16 fev. 2023.

WHO. **WHO Coronavirus (COVID-19) Dashboard**. Disponível em: <<https://covid19.who.int>>. Acesso em: 30 mar. 2021.

WICKHAM, H. et al. **ggplot2: Create Elegant Data Visualisations Using the Grammar of Graphics**. , 23 abr. 2024. Disponível em: <<https://cran.r-project.org/web/packages/ggplot2/index.html>>. Acesso em: 10 mar. 2025

WU, J. T.; LEUNG, K.; LEUNG, G. M. Nowcasting and forecasting the potential domestic and international spread of the 2019-nCoV outbreak originating in Wuhan, China: a modelling study. **The Lancet**, v. 395, n. 10225, p. 689–697, 29 fev. 2020.

YILDIRIM, M.; GEÇER, E.; AKGÜL, Ö. The impacts of vulnerability, perceived risk, and fear on preventive behaviours against COVID-19. **Psychology, Health & Medicine**, v. 26, n. 1, p. 35–43, 2 jan. 2021.

YOSHIKAWA, Y.; KAWACHI, I. Association of Socioeconomic Characteristics With Disparities in COVID-19 Outcomes in Japan. **JAMA Network Open**, v. 4, n. 7, p. e2117060, 14 jul. 2021.

YU, D. et al. Whether Urbanization Has Intensified the Spread of Infectious Diseases—Renewed Question by the COVID-19 Pandemic. **Frontiers in Public Health**, v. 9, 24 nov. 2021.

ZHAO, X. et al. Malaria Risk Map Using Spatial Multi-Criteria Decision Analysis along Yunnan Border During the Pre-elimination Period. **The American Journal of Tropical Medicine and Hygiene**, v. 103, n. 2, p. 793–809, ago. 2020.

ZORAN, M. A. et al. Assessing the relationship between surface levels of PM2.5 and PM10 particulate matter impact on COVID-19 in Milan, Italy. **Science of The Total Environment**, v. 738, p. 139825, 10 out. 2020.