



Ministério da Saúde

FIOCRUZ
Fundação Oswaldo Cruz



ESCOLA NACIONAL DE SAÚDE PÚBLICA
SERGIO AROUCA
ENSP

João Henrique de Araujo Moraes

Distribuição espaço-temporal da Covid-19 em São Paulo: contextos socioeconômicos, interiorização e o papel dos frigoríficos

Rio de Janeiro

2022

João Henrique de Araujo Morais

Distribuição espaço-temporal da Covid-19 em São Paulo: contextos socioeconômicos, interiorização e o papel dos frigoríficos

Dissertação apresentada ao Programa de Pós-graduação em Epidemiologia em Saúde Pública, da Escola Nacional de Saúde Pública Sergio Arouca, na Fundação Oswaldo Cruz, como requisito parcial para obtenção do título de Mestre em Ciências. Área de concentração: Métodos quantitativos em epidemiologia.

Orientador: Prof. Dr. Oswaldo Gonçalves Cruz.

Coorientadora: Prof^ª. Dr^ª. Laís Picinini Freitas.

Rio de Janeiro

2022

Título do trabalho em inglês: Spatiotemporal modeling of Covid-19 in São Paulo: socio-economic contexts and the role of slaughterhouses in the disease distribution.

O presente trabalho foi realizado com apoios incoexistentes da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001 e da Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ).

Catálogo na fonte
Fundação Oswaldo Cruz
Instituto de Comunicação e Informação Científica e Tecnológica em Saúde
Biblioteca de Saúde Pública

M827d Moraes, João Henrique de Araujo.
Distribuição espaço-temporal da Covid-19 em São Paulo:
contextos socioeconômicos, interiorização e o papel dos frigoríficos /
João Henrique de Araujo Moraes. -- 2022.
126 f. : il. color. ; graf. ; mapas ; tab.

Orientador: Oswaldo Gonçalves Cruz.
Coorientadora: Laís Picinini Freitas.
Dissertação (mestrado) – Fundação Oswaldo Cruz, Escola Naci-
onal de Saúde Pública Sergio Arouca, Rio de Janeiro, 2022.

1. COVID-19. 2. Doenças Transmissíveis. 3. Análise Espaço-
Temporal. 4. Fatores Socioeconômicos. 5. Saúde do Trabalhador.
I. Título.

CDD – 23.ed. – 616.2098161

João Henrique de Araujo Morais

Distribuição espaço-temporal da Covid-19 em São Paulo: contextos socioeconômicos, interiorização e o papel dos frigoríficos

Dissertação apresentada ao Programa de Pós-graduação em Epidemiologia em Saúde Pública, da Escola Nacional de Saúde Pública Sergio Arouca, na Fundação Oswaldo Cruz, como requisito parcial para para obtenção do título de Mestre em Ciências. Área de concentração: Métodos quantitativos em epidemiologia.

Aprovada em: 22 de fevereiro de 2022.

Banca Examinadora

Prof. Dr. Marcelo Ferreira da Costa Gomes

Fundação Oswaldo Cruz – Programa de Computação Científica

Prof^a. Dr^a. Marilia Sá Carvalho

Fundação Oswaldo Cruz – Programa de Computação Científica

Prof. Dr. Oswaldo Gonçalves Cruz

Fundação Oswaldo Cruz – Programa de Computação Científica

Rio de Janeiro

2022

À Dona Marylands.

AGRADECIMENTOS

Agradeço a meus pais, Flávio e Inez, que foram companhia diária e alento durante esse período.

Ao Professor Oswaldo, pela compreensão, partilha e orientação. À Laís, também pela orientação, pelo apoio e sensibilidade.

À Fernanda, pelo acolhimento desde o primeiro dia de mestrado e pelas trocas que a partir daí vieram. Por lembrar, também, do sentido político que permeia nossas vidas e nosso trabalho. À Miwa, pelo apoio, conforto e escuta constantes. À Paola, Isiyara, Camylla e Heloísa pela parceria e pelo carinho que, mesmo que virtual, tornou a jornada mais leve.

À CAPES e à FAPERJ por terem possibilitado a realização desse trabalho.

Agradeço, por fim, aos membros da banca de qualificação e defesa, pela cuidadosa revisão e por seus comentários, que contribuíram com o pensamento e desenvolvimento dessa dissertação.

A falta de engajamento crítico com a comida que comemos demonstra a que ponto a mercantilização se tornou a principal maneira pela qual percebemos o mundo.

Angela Davis, 2016.

[...] vai ser difícil vermos uma mudança, justamente por causa da questão do lucro. Eles não tão vendo um animal, tão vendo uma carne pra exportar. É um bife, é um produto enlatado. E ele tem que estar pronto.

Gabriela Chaves Marra, 2020.

RESUMO

A Covid-19 foi identificada pela primeira vez no Brasil em fevereiro de 2020, na cidade de São Paulo. A doença se concentrou primeiramente nos grandes centros, mas se espalhou de forma rápida para o restante do país, atingindo de forma diferencial as populações socioeconomicamente vulneráveis. O grupo ocupacional dos trabalhadores de frigoríficos esteve entre os mais afetados, devido a características da dinâmica e do ambiente de trabalho. Visto a histórica contribuição das análises espaciais e espaço-temporais para o entendimento da dinâmica de doenças infecciosas, o estudo se propôs a estimar, através de modelagem estatística sob a perspectiva Bayesiana, a distribuição espaço-temporal de Síndrome Respiratória Aguda Grave causada por Covid-19 (SRAG-COVID) no estado de São Paulo entre março de 2020 e agosto de 2021. Atentou-se para as especificidades do processo de disseminação pelo território e para a relação dessa distribuição com fatores socioeconômicos, demográficos e a presença de frigoríficos. No período de estudo registrou-se 509.855 casos e 147.070 óbitos por SRAG-COVID. Houve aglomerados iniciais de casos e óbitos na Região Metropolitana de São Paulo e um posterior movimento rumo às regionais do interior do estado. Essas regionais foram as mais afetadas durante o ano de 2021, ano que, até o mês de agosto, havia registrado 57,38% mais casos e 95,67% mais óbitos do que o ano de 2020 completo. Para a modelagem, considerou-se mais adequado o modelo com componentes espacial e temporal estruturados e uma interação espaço-tempo a nível de região de saúde. Os coeficientes das covariáveis foram mantidos fixos no tempo. Municípios maiores e de melhor índice socioeconômico se mostraram mais afetados em todo o período para casos e óbitos, e a presença de frigoríficos se apresentou como um fator associado ao aumento da incidência e mortalidade por SRAG-COVID nos municípios, mesmo após considerar potenciais variáveis confundidoras. O estudo contribuiu para a descrição da dinâmica espaço-temporal da doença no estado e trouxe destaque à manifestação do efeito das precárias condições de trabalho sobre os desfechos da Covid-19 em nível ecológico, trazendo para a discussão a histórica invisibilização desses trabalhadores e a contraditória definição de essencialidade do trabalho que não serve aos interesses da população, mas à manutenção dos patamares de acumulação.

Palavras-chave: COVID-19, Doenças Transmissíveis, Análise Espaço-Temporal, Fatores Socioeconômicos, Saúde do Trabalhador.

ABSTRACT

Covid-19 was first identified in Brazil in February 2020, in the city of São Paulo. It has first affected larger cities but it rapidly spread to the rest of the country, impacting overall socioeconomically vulnerable populations. The occupational group of slaughterhouse workers has been one of the most affected, due to the job dynamics and the work environment. Given the historical contribution of spatial and spatio-temporal analysis to the understanding of infectious disease dynamics, the present study aimed to estimate, through statistical modeling under the Bayesian perspective, the spatio-temporal distribution of Severe Acute Respiratory Infections caused by Covid-19 (SARI-COVID) in the state of São Paulo between March 2020 and August 2021. We draw attention to the complexities and specificities in the spread of the disease, and to its relation with socio-economic and demographic factors and the presence of slaughterhouses in the municipalities. In the study period, 509,855 SARI-COVID cases and 147,070 deaths were registered. There has been an initial clustering of cases and deaths in the metropolitan region of São Paulo, followed by a movement to the regions in the state countryside. These regions held the highest case and death rates in 2021 (up until August), which have been respectively 57.38% and 95.67% higher than 2020. The larger and more socioeconomically favorable municipalities were most affected throughout the study period, and the presence of slaughterhouses was associated with an 8% increase in both SARI-COVID incidence and mortality, even after adjustment by potential confounders. The study therefore contributed to the characterization of the spatio-temporal dynamics of Covid-19 in São Paulo state, and shed light over the effect of precarious working conditions in Covid-19 outcomes in the ecological level. We bring to the discussion the historical marginalization of slaughterhouse workers and the contradictory definition of work essentiality, which does not favor the population but capital accumulation and the structural maintenance of inequalities.

Keywords: COVID-19, Communicable Diseases, Spatio-Temporal Analysis, Socioeconomic Factors, Occupational Health.

LISTA DE ILUSTRAÇÕES

Figura 1	Regionalização do estado de São Paulo. Elaboração Própria.	38
Quadro 1	Esquema para categorização dos municípios em relação à hierarquia urbana.	43
Quadro 2	Códigos de Subclasse CNAE 2.0 Relacionados à Atividade Frigorífica (IBGE, 2015)	45
Figura 2	Modelo teórico ecológico dos processos e seus fatores determinantes de novos casos, hospitalizações e óbitos por Covid-19.	53
Figura 3	Casos de SRAG-COVID por semana de primeiros sintomas, entre março de 2020 e agosto de 2021 no estado (UF) e divisão entre Grande São Paulo e restante do estado. Linha pontilhada vertical: divisão do período entre as duas principais curvas de casos.	56
Figura 4	Distribuição espacial por município de casos (a, b) e óbitos (c, d) por SRAG-COVID por 100.000 habitantes entre dois períodos (curvas), de março de 2020 a agosto de 2021, suavizados espacialmente, junto aos aglomerados encontrados pelos indicadores locais de associação espacial (SE 43/2020 – 32/2021).	60
Figura 5	Distribuição espacial das variáveis GeoSES (a), IVS (b), Hierarquia Urbana (c), Atividade Frigorífica em 2020 (d), Proporção de Idosos em 2020 (e) e % População SUS Dependente em 2020 (f), no estado de São Paulo.	63
Figura 6	Diagramas de dispersão com linha auxiliar loess da variável GeoSES com as variáveis IVS (a), proporção de idosos (b) e Porcentagem da população SUS dependente (c). Ao topo, o coeficiente de correlação linear (r) estimado. Boxplots dos índices GeoSES (d) e IVS (e) entre as categorias de Hierarquia Urbana.	65
Figura 7	Casos de SRAG-COVID semanais por 100.000 habitantes suavizados pelo método loess entre março de 2020 e agosto de 2021 por quintis de GeoSES (a), categoria de IVS (b), hierarquia urbana (c) e atividade frigorífica (d).	66

Figura 8	Casos de SRAG-COVID por 100.000 habitantes em São Paulo em cada ano, de março de 2020 a agosto de 2021, por categoria de atividade frigorífica, entre os quintis de GeoSES (a) e categorias de hierarquia urbana (b).	68
Figura 9	Efeitos temporais estruturados (γ) estimados, junto ao intervalo de credibilidade de 95%, nos modelos estatísticos para Casos (a) e Óbitos (b) por SRAG-COVID no estado de São Paulo.	72
Figura 10	Efeitos espaciais estruturados (ϕ) exponenciados para os modelos estatísticos de casos (a) e óbitos (b) por SRAG-COVID, no estado de São Paulo. Polígonos preenchidos com pontilhado não tiveram o valor 1 contido em seu intervalo de credibilidade para ϕ exponenciado.	73
Figura 11	Efeitos da interação espaço-tempo (δ) exponenciados para o modelo estatístico de casos de SRAG-COVID por Região de Saúde, a cada mês, no estado de São Paulo	73
Figura 12	Interações espaço-tempo (δ) exponenciadas para o modelo estatístico de casos de SRAG-COVID representadas na forma de séries temporais, por Região de Saúde, no estado de São Paulo	76
Figura 13	Efeitos das covariáveis ajustados e exponenciados para os modelos estatísticos de casos e óbitos de SRAG-COVID. Representa-se o valor pontual da média junto aos intervalos de credibilidade de 95%, em azul. Efeitos cujos intervalos não incluem o valor 1 estão marcados na cor vermelha.	78
Figura 14	Risco relativo (RR) para casos de SRAG-COVID estimado pelo modelo estatístico (média) entre os municípios do estado de São Paulo em cada mês	79
Figura 15	Distribuição dos riscos relativos (RR) para casos de SRAG-COVID no estado de São Paulo estimados para os municípios com e sem atividade frigorífica ao longo dos meses do estudo	81
Quadro S1	Frequência absoluta (n) e relativa (%) das subclasses CNAE 2.0 relativas à atividade frigorífica no estado de São Paulo, em 2020.	109
Figura S1	Distribuição espacial do IVS em sua forma categorizada em	110

	Baixo e Médio/Alto, no estado de São Paulo.	
Figura S2	Histograma da razão de trabalhadores de frigoríficos por total de trabalhadores no município, multiplicada por 1.000.	111
Figura S3	Óbitos por SRAG-COVID semanais por 100.000 habitantes suavizados pelo método loess por quintis de GeoSES (a), categoria de IVS (b), hierarquia urbana (c) e atividade frigorífica (d).	112
Figura S4	Letalidade hospitalar (HCFR, número de óbitos por SRAG-COVID/número de casos de SRAG-COVID) entre as categorias de GeoSES (a), IVS (b), Hierarquia urbana (c), e Atividade Frigorífica (d) em 2020 e 2021.	113
Figura S5	Médias dos efeitos aleatórios espaciais conjuntos (a) e não estruturado (c) em cada município e temporais estruturado (b) e não estruturado (d) em cada mês, no modelo para casos de SRAG-COVID. Linhas em cinza representam o intervalo de credibilidade de 95%, e as observações na cor vermelha indicam que tal intervalo não inclui o valor 1.	114
Figura S6	Estimas da média e intervalos de credibilidade de 95% para o coeficiente relativo ao índice GeoSES variando no tempo sem estrutura de correlação) para o modelo estatístico para casos de SRAG-COVID	115
Figura S7	Efeitos da interação espaço-tempo exponenciados para modelo estatístico para óbitos por SRAG-COVID por Região de Saúde, a cada mês.	116
Figura S8	Risco relativo (RR) para óbitos de SRAG-COVID estimado pelo modelo estatístico (média) entre os municípios em cada mês	117
Figura S9	Probabilidades do risco relativo estimado para casos de SRAG-COVID ser maior do que 1 em cada município, em cada mês	118
Figura S10	Probabilidades do risco relativo estimado para óbitos de SRAG-COVID ser maior do que 1 em cada município, em cada mês	118
Quadro A1	Descrição das variáveis que compõem o índice GeoSES.	119
Quadro B1	Descrição das variáveis que compõem o índice IVS.	123

LISTA DE TABELAS

Tabela 1	Número de casos e óbitos de SRAG-COVID em dois períodos (curvas) no estado de São Paulo, março de 2020 a agosto de 2021. Incidência e Mortalidade calculadas por 100.000 habitantes.	57
Tabela 2	Casos e Óbitos por SRAG-COVID nas primeira e segunda curvas agregados por DRS, estado de São Paulo, março de 2020 a agosto de 2021. Incidência e Mortalidade expressas por 100.000 habitantes.	58
Tabela 3	Total de vínculos encontrados na RAIS 2020, número de vínculos relacionados à atividade frigorífica e sua razão, total e por DRS, estado de São Paulo, 2020.	62
Tabela 4	Exemplos de composições de efeitos aleatórios testadas para a estrutura do modelo estatístico para casos de SRAG-COVID.	69
Tabela 5	Efeitos exponenciados (estimativa pontual da média e intervalo de credibilidade de 95%). Valores cujo intervalo não contempla o valor 1 estão marcados em negrito.	77
Tabela S1	Índices I de Moran para autocorrelação espacial para casos e óbitos por SRAG-COVID, no estado de São Paulo, de março de 2020 a agosto de 2021.	109

LISTA DE ABREVIATURAS E SIGLAS

BYM	Besag-York-Mollié
CAR	Condicional Autorregressivo
CFR	Letalidade (<i>Case-Fatality Rate</i>)
CNAE	Classificação Nacional de Atividades Econômicas
DCNT	Doenças Crônicas Não Transmissíveis
DIC	Critério de Informação de Deviance
DORT	Distúrbios Osteomusculares Relacionados ao Trabalho
DRS	Departamento Regional de Saúde
ESF/APS	Estratégia Saúde da Família/Atenção Primária à Saúde
GMRF	Campos Aleatórios de Markov Gaussianos
HCFR	Letalidade Hospitalar (<i>Hospitalized Case-Fatality Rate</i>)
HIV/AIDS	Vírus da Imunodeficiência Humana/Síndrome da Imunodeficiência Adquirida
I.I.D.	Independente e Identicamente Distribuído
IBGE	Instituto Brasileiro de Geografia e Estatística
IDH	Índice de Desenvolvimento Humano
INLA	Aproximação de Laplace Aninhada Integrada
IPEA	Instituto de Pesquisa Econômica Aplicada
IVS	Índice de Vulnerabilidade Social
LER	Lesão por Esforço Repetitivo
LISA	Indicadores Locais de Associação Espacial
MCMC	<i>Markov Chain Monte Carlo</i>
OMS	Organização Mundial da Saúde
PCA	Análise de Componentes Principais
PDET	Programa de Disseminação das Estatísticas do Trabalho
RAIS	Relação Anual de Informações Sociais
REGIC	Regiões de Influência das Cidades
RR	Risco Relativo
RRAS	Redes Regionais de Atenção à Saúde
RW	Passeio Aleatório (<i>Random Walk</i>)
SARS	<i>Severe Acute Respiratory Syndrome</i>

SE	Semana Epidemiológica
SEADE	Fundação Sistema Estadual de Análise de Dados
SIF	Serviço de Inspeção Federal
SIG	Sistema de Informação Geográfica
SIVEP-Gripe	Sistema de Informação de Vigilância Epidemiológica da Gripe
SRAG	Síndrome Respiratória Aguda Grave
SRAG-COVID	Síndrome Respiratória Aguda Grave causada por Covid-19
SRAG-FLU	Síndrome Respiratória Aguda Grave causada por Influenza
UDH	Unidade de Desenvolvimento Humano
ZINBI	Binomial Negativa Inflada em Zero
ZIP	Poisson Inflado em Zero

SUMÁRIO

1 INTRODUÇÃO	17
2 REVISÃO DA LITERATURA	20
2.1 DISTRIBUIÇÃO DA COVID-19 E DISPARIDADES NA POPULAÇÃO	20
2.2 SAÚDE DOS TRABALHADORES DE FRIGORÍFICOS EM TEMPOS DE COVID-19	23
2.3 ANÁLISES ESPACIAIS E ESPAÇO-TEMPORAIS	26
2.3.1 Modelagem Bayesiana em estudos epidemiológicos	26
2.3.2 INLA	29
2.3.3 Interações espaço-tempo e coeficientes variáveis	31
2.4 SÍNDROME RESPIRATÓRIA AGUDA GRAVE (SRAG)	33
3 JUSTIFICATIVA	35
4 OBJETIVOS	36
4.1 OBJETIVO GERAL	36
4.2 OBJETIVOS ESPECÍFICOS	36
5 METODOLOGIA	37
5.1 DESENHO DO ESTUDO	37
5.2 REGIÃO DO ESTUDO.....	37
5.3 PERÍODO DO ESTUDO	38
5.4 DADOS E VARIÁVEIS	39
5.4.1 Desfecho	39
5.4.2 Covariáveis	40
5.4.2.1 GeoSES.....	40
5.4.2.2 Índice de Vulnerabilidade Social (IVS).....	41
5.4.2.3 Hierarquia urbana	42
5.4.2.4 Proporção de idosos.....	44
5.4.2.5 População SUS dependente	44
5.4.2.6 Frigoríficos	44
5.5 ANÁLISES ESTATÍSTICAS	46
5.5.1 Análise exploratória	46
5.5.2 Modelagem	47
5.5.3 Software	50
5.6 ASPECTOS ÉTICOS	51
6 RESULTADOS	52
6.1 MODELO TEÓRICO.....	52
6.2 ANÁLISE EXPLORATÓRIA	55
6.2.1 SRAG-COVID em São Paulo	55
6.2.2 Distribuição e correlação entre as covariáveis	61

6.2.3 Incidência e mortalidade de SRAG-COVID entre as covariáveis	65
6.3 MODELAGEM ESTATÍSTICA	68
6.3.1 Estrutura dos modelos estatísticos	68
6.3.2 Resultados dos modelos estatísticos	71
7 DISCUSSÃO	82
7.1 DISTRIBUIÇÃO ESPAÇO-TEMPORAL DE SRAG-COVID EM SÃO PAULO	82
7.2 FATORES ASSOCIADOS À DISTRIBUIÇÃO	85
7.3 O PAPEL DOS FRIGORÍFICOS	88
7.4 LIMITAÇÕES E TRABALHOS FUTUROS	91
8 CONSIDERAÇÕES FINAIS.....	93
REFERÊNCIAS	94
APÊNDICE A – MATERIAL SUPLEMENTAR.....	109
ANEXO A – COMPOSIÇÃO DO GEOSSES.....	119
ANEXO B – COMPOSIÇÃO DO IVS	123

1 INTRODUÇÃO

A Covid-19, doença causada pelo vírus SARS-CoV-2, foi identificada pela primeira vez no Brasil em 25 de fevereiro de 2020, na cidade de São Paulo (DE SOUZA et al., 2020). A doença afetou primeiramente os municípios mais populosos e grandes centros, mas se espalhou de forma rápida para o restante do estado e do país (DE SOUZA et al., 2020; RIBEIRO et al., 2020; CASTRO et al., 2021a). No estado de São Paulo, a tardia adoção de medidas de distanciamento social contribuiu para esse fenômeno (NIQUINI et al., 2020), de modo que no fim de maio de 2020 os casos e óbitos semanais pela doença no interior já eram maiores que os números da capital (CASTRO et al., 2021a). Além de ser o estado mais populoso do Brasil (21,86% da população nacional (IBGE, 2020)), estimou-se que São Paulo possuía as maiores frequências absolutas e relativas de adultos em alto risco para o agravamento da Covid-19 (REZENDE et al., 2020). Até o início de maio de 2021, mais de 3 milhões de casos e 100 mil óbitos pela doença foram registrados no estado, correspondendo respectivamente a 19,8% e 23,9% do total do país (SEADE, 2021).

Desde a declaração de pandemia de Covid-19 pela Organização Mundial da Saúde (OMS) em 11 de março de 2020 (ORGANIZAÇÃO MUNDIAL DA SAÚDE, 2020), tem-se reforçado que o vírus não atinge as populações de forma democrática (AHMED et al., 2020; CORDES; CASTRO, 2020; NUNES, 2020; ALBUQUERQUE; RIBEIRO, 2021; SEGATA et al., 2021b). Assim, diversos estudos têm documentado a forma desigual com que, como observado em outras epidemias (BUCCHIANERI, 2010; TRICCO et al., 2012; MAESTRIPIERI, 2021), as populações social e economicamente vulneráveis têm sido mais atingidas (LI et al., 2021; MATTA et al., 2021; RIBEIRO et al., 2021), desde o processo de infecção até o agravamento da doença. Precárias condições de habitação, transporte e trabalho, assim como o baixo acesso a recursos básicos como abastecimento regular de água e saneamento, prejudicam a prática de ações contra a disseminação do novo coronavírus (COELHO et al., 2020; CORDES; CASTRO, 2020; KHALATBARI-SOLTANI et al., 2020; OLIVEIRA et al., 2020; LI et al., 2021). A maior presença de comorbidades e cenários de insegurança alimentar entre essas populações, assim como o pior acesso à saúde, são fatores que se relacionam com o maior risco de agravamento da doença (CARVALHO; PIRES; XAVIER, 2020; CORBURN et al., 2020; LORENZ et al., 2021).

Os trabalhadores de frigoríficos estão entre os grupos ocupacionais mais atingidos pelo SARS-CoV-2. Constantes e repetidos surtos de Covid-19 têm sido observados nessas instalações em países da Europa, nos Estados Unidos e no Brasil (FRENCH NATIONAL

ACADEMY OF MEDICINE, 2020; TOOGE, 2020; RIVERA ARIZA et al., 2021). A dinâmica e o ambiente de trabalho, o contexto socioeconômico dos trabalhadores, e a manutenção desse seguimento como essencial são fatores que contribuíram para a disseminação da Covid-19 nesses locais (FRENCH NATIONAL ACADEMY OF MEDICINE, 2020; MIDDLETON; REINTJES; LOPES, 2020; GRANADA et al., 2021). Um estudo de soroprevalência do SARS-CoV-2 na Itália (MODENESE et al., 2021) e um levantamento de dados da seguridade social no Brasil (MAENO, 2021) mostraram que, após os profissionais da saúde, os trabalhadores de frigoríficos estão entre os grupos ocupacionais com mais registros de infecção pela doença. No Rio Grande do Sul, estado com alta concentração de frigoríficos, esses trabalhadores representavam 32% do total de casos no estado até junho de 2020 (SEGATA et al., 2021a). Análises cartográficas e espaciais no Brasil foram realizadas buscando destrinchar a influência dessas instalações sobre o processo de disseminação da Covid-19, principalmente para municípios menores (HECK et al., 2020; NASCIMENTO; TOMBINI; RIPPLINGER, 2020; SERRA; OLIVEIRA, 2020; SILVEIRA et al., 2020).

O processo de difusão de doenças infecciosas é explicitamente espacial (CORDES; CASTRO, 2020) e temporal (LÓPEZ-QUÍLEZ, 2019), onde revelam-se padrões geográficos “tão diversos quanto desiguais” (ALBUQUERQUE; RIBEIRO, 2021). A incorporação do espaço e tempo em estudos epidemiológicos não é recente, mas tem se tornado mais presente ao longo dos últimos 30 anos com os avanços em recursos computacionais, geolocalização dos dados, desenvolvimento de métodos e softwares e melhorias no acesso à literatura da área (CARPENTER, 2011; MELIKER; SLOAN, 2011; AUCHINCLOSS et al., 2012). Tais estudos, para além de identificar áreas e períodos de risco elevado para a doença, contribuem para a compreensão da forma com que fatores, como socioeconômicos e demográficos, se relacionam com a doença e se manifestam no espaço e no tempo (LÓPEZ-QUÍLEZ, 2019; PAUL et al., 2021). Análises espaciais e espaço-temporais têm se mostrado cruciais para o entendimento da dinâmica de doenças infecciosas, como para malária (NOBRE; SCHMIDT; LOPES, 2005; ACHCAR et al., 2011; NOOR et al., 2014), dengue (COSTA et al., 2015; ABD NAEEM; ABDUL RAHMAN, 2017; MARTÍNEZ-BELLO; LÓPEZ-QUÍLEZ; PRIETO, 2018) e influenza (LEE; BANSAL, 2017; DA COSTA et al., 2018; MELLOR et al., 2018). No contexto da Covid-19, estudos do tipo no mundo e no Brasil têm revelado as evidentes desigualdades de incidência e mortalidade pela doença entre grupos e territórios (BERMUDI et al., 2021; BILAL et al., 2021; LI et al., 2021; LORENZ et al., 2021; PAUL et al., 2021) e evidenciado o cenário múltiplo e complexo da epidemia nos países (CASTRO et al., 2021a; JOHNSON; RAVI; BRANEON, 2021; NEELON et al., 2021).

Dessa forma, o presente estudo objetivou descrever a distribuição espaço-temporal da Covid-19 no estado de São Paulo entre março de 2020 e agosto de 2021, utilizando dados de Síndrome Respiratória Aguda Grave (SRAG). Explorou-se a forma com que fatores socioeconômicos e a hierarquia urbana dos municípios se relacionaram com essa distribuição, voltando atenções também para o papel dos frigoríficos sobre esse processo. Para isso, foram utilizados modelos estatísticos espaço-temporais sob a perspectiva Bayesiana, com componentes de interação espaço-tempo, a fim de melhor capturar as especificidades contextuais e a complexidade da difusão da doença sobre o território do estado.

2 REVISÃO DA LITERATURA

2.1 DISTRIBUIÇÃO DA COVID-19 E DISPARIDADES NA POPULAÇÃO

Historicamente, reconhece-se que a distribuição de doenças infecciosas não se dá de forma uniforme sobre as populações (FARMER, 1996). Um olhar para outras epidemias nos revela que as desigualdades sociais têm papel determinante na distribuição e manutenção de tais doenças, como se viu com a H1N1 (TRICCO et al., 2012), SARS (BUCCHIANERI, 2010), e o HIV/AIDS (AIDALA et al., 2016; MAESTRIPIERI, 2021). Durante a pandemia de Covid-19, a comunidade científica tem constantemente enfatizado que a doença não atingiu a todos de forma igual tampouco democraticamente, mas revelou e acentuou desigualdades no que se tange a raça/cor, gênero, classe social, lugar e ocupação (AHMED et al., 2020; CORDES; CASTRO, 2020; DORN; COONEY; SABIN, 2020; ALBUQUERQUE; RIBEIRO, 2021; MAENO, 2021; RIBEIRO et al., 2021). Reconhecida sua transmissão majoritariamente pelo ar (CDC, 2020), voltou-se atenção ao risco elevado sobre o qual indivíduos dependentes do transporte público e aqueles considerados “trabalhadores essenciais” desde o início da pandemia estavam (CORDES; CASTRO, 2020; MAENO, 2021). As disparidades observadas, no entanto, não são geradas somente pelas diferenças na exposição e infecção, mas também pelos fatores que condicionam o agravamento e morte pela doença (BERMUDI et al., 2021; RIBEIRO et al., 2021). Assim, diversos estudos desde a declaração de pandemia de Covid-19 buscaram quantificar essas desigualdades observáveis entre os desfechos da doença, chamando atenção para sua distribuição desigual entre os grupos populacionais e regiões.

Dentre as disparidades mais documentadas estão aquelas observadas entre os grupos de raça/cor. No Brasil, estudos observacionais com dados do Sistema de Informação de Vigilância Epidemiológica da Gripe (SIVEP-Gripe) permitiram dimensionar essa diferença. Após hospitalização, observou-se que pardos e pretos tiveram um risco respectivamente 45% e 32% maior de mortalidade quando comparados aos brancos (BAQUI et al., 2020; PERES et al., 2021). Esses achados também se demonstraram em estudos de soroprevalência (LI et al., 2021), onde na cidade de São Paulo encontrou-se prevalência de anticorpos para o SARS-CoV-2 2,7 vezes maior entre os pardos e pretos em relação aos brancos (TESS et al., 2021). Além das disparidades raciais, também destacou-se o gradiente socioeconômico para variáveis como renda, educação e habitação – onde a piora nesses indicadores implicava em aumento significativo nas taxas de mortalidade (RIBEIRO et al., 2021).

Tanto os fatores individuais quanto contextuais atuam em conjunto na determinação

dos desfechos da Covid-19. Assim, muita atenção também tem sido dada a estudos que descreviam as diferenças nos desfechos da doença entre as áreas e territórios, visto que as desigualdades socioespaciais e geográficas atuaram como importantes condicionantes na distribuição e na dinâmica da doença (ALBUQUERQUE; RIBEIRO, 2021). Em seu processo de dispersão entre os países, a Covid-19 se instaurou nas metrópoles e grandes centros urbanos - os espaços “luminosos” (SILVEIRA et al., 2020; ALBUQUERQUE; RIBEIRO, 2021) - e se espalhou posteriormente para os municípios mais conectados e por fim para o interior dos estados (FORTALEZA et al., 2020b; RIBEIRO et al., 2020; ALBUQUERQUE; RIBEIRO, 2021; CASTRO et al., 2021a). Estudos nos meses iniciais da pandemia relataram a concentração dos casos nas áreas mais centrais e mais ricas dos estados (CESTARI et al., 2021; NAKADA; URBAN, 2021; BERMUDI et al., 2021; LI et al., 2021). A chegada da epidemia a municípios menores, no entanto, é um processo preocupante, quando se trata de limitações de recursos, acesso à saúde, e diferenças na distribuição etária e de comorbidades da população (COSTA; COTA; FERREIRA, 2020; ALBUQUERQUE; RIBEIRO, 2021; GAMLIN et al., 2021; PAUL et al., 2021). Gamlin e colaboradores (2021) ainda alertam que a situação em municípios menores pode ser subestimada ao analisar apenas taxas de incidência e mortalidade, uma vez que estes podem apresentar baixas taxas mas uma crítica situação quando se trata de outros indicadores, como letalidade.

Para além da distribuição da doença segundo a hierarquia e conectividade entre os municípios, estudos se propuseram a identificar fatores contextuais – na maioria, fatores socioeconômicos e de vulnerabilidade social – que se relacionavam com maiores números de casos e óbitos por Covid-19 nas regiões. No município de São Paulo, observou-se uma inversão na associação entre contexto socioeconômico nos distritos administrativos e mortalidade por Covid-19 ao longo do tempo. Nas primeiras semanas após a chegada da doença ao município, as áreas de melhor índice socioeconômico concentravam mais óbitos, mas três semanas depois em diante essa relação se inverteu (BERMUDI et al., 2021). Ao observar mais amplo recorte temporal na cidade, mostrou-se posteriormente que a renda per capita das regiões se associava de forma inversa à letalidade hospitalar (LORENZ et al., 2021). Já a nível do estado de São Paulo, também encontrou-se associação inversa de fatores como renda per capita e escolaridade com o número de hospitalizações por SRAG-COVID nos municípios, através de modelagem espaço-temporal (LI et al., 2021). Outras estudos de regressão espacial (DE SOUZA; MACHADO; DO CARMO, 2020; DEMENECH et al., 2020; CASTRO et al., 2021b; CESTARI et al., 2021) e de clusters (ANDRADE et al., 2020; ALMEIDA ANDRADE et al., 2021; QUININO et al., 2021) foram realizadas pelo Brasil e mostraram concentração inicial

dos casos nas regiões centrais mais populosas dos estados, assim como associações diretas com índice de Gini (DEMENECH et al., 2020; SCHNEIDER et al., 2020; QUININO et al., 2021) e densidade populacional (SCHNEIDER et al., 2020; NAKADA; URBAN, 2021; QUININO et al., 2021).

Fora do Brasil, estudos que buscavam compreender o efeito de fatores socioeconômicos e de vulnerabilidade social nos desfechos de Covid-19 foram abundantes. Diversos encontram-se nos Estados Unidos: Alguns estudos espaciais relataram coincidência espacial entre áreas de maior porcentagem de população negra e maiores taxas de incidência de Covid-19 em Nova York (CORDES; CASTRO, 2020; WHITTLE; DIAZ-ARTILES, 2020; BILAL et al., 2021), e outras cidades como Filadélfia e Illinois (BILAL et al., 2021; CHEN; KRIEGER, 2021). Em uma breve discussão, Johnson e colaboradores (2021) mostram que os resultados encontrados em estudos espaciais que consideravam a vulnerabilidade eram inconsistentes. Associações diretas foram encontradas entre vulnerabilidade social e incidência e mortalidade por Covid-19 (KARAYE; HORNEY, 2020; KHAZANCHI et al., 2020), associações somente com a letalidade (NAYAK et al., 2020), e associações que variavam no espaço (WANG et al., 2020) e no tempo (JOHNSON; RAVI; BRANEON, 2021; NEELON et al., 2021). Oroszi e colaboradores (2021) também relataram um fenômeno de inversão nos achados ao utilizar diferentes desfechos. Em um estudo durante a segunda onda de Covid-19 na Hungria, os autores mostraram que as áreas mais vulneráveis apresentavam menores taxas de incidência e mortalidade, mas a direção dessa associação se invertia quando o desfecho passava a ser letalidade. Tal observação é compatível com o hipotetizado por Gamlin e colaboradores (2021) e Albuquerque e Ribeiro (2021), onde os maiores e mais ricos municípios apresentam maiores taxas por conta de sua maior densidade, conectividade e concentração de atividades econômicas mas possuem também maior capacidade de resposta. Os municípios menores e mais vulneráveis, por outro lado, aparentam ser menos atingidos pelas menores taxas de incidência mas podem estar sob uma situação muito mais crítica quando se observa letalidade.

Assim, o presente estudo busca aprofundar e contribuir com essas associações encontradas pelo Brasil em termos dos macrodeterminantes, como índices socioeconômico e de vulnerabilidade, assim como explorar a difusão da doença pela hierarquia de conectividade dos municípios em um maior recorte temporal, permitindo a verificação dessas associações ao longo do tempo. Além disso, busca-se entender a influência de um fator específico relacionado a condições do trabalho vulnerável em municípios menores - os frigoríficos - a ser detalhado na seção 2.2.

2.2 SAÚDE DOS TRABALHADORES DE FRIGORÍFICOS EM TEMPOS DE COVID-19

A atividade frigorífica faz parte do modelo de agricultura industrial e tem suas bases no agronegócio (MARRA, 2019). É um modelo que ao longo das últimas décadas se intensificou através de incentivos fiscais, especialização de seu maquinário e a característica exploração de seus trabalhadores (MARRA, 2019). Com esse modelo, o Brasil passou a figurar como um dos maiores produtores de carne bovina do mundo - em 2017, o rebanho no país constava de 221,81 milhões de cabeças e foram realizados mais de 39 milhões de abates (ABIEC, 2018). Neves (2012) descreve que em 2010 a capacidade de abate no país pelo Serviço de Inspeção Federal (SIF) era de 163 mil cabeças por dia. Apesar dos exorbitantes números para a economia, tem-se o negócio dos frigoríficos como algo afastado da população, “mantendo à distância a sujeira, a doença, a violência e a exploração” (DIAS, 2009). Os frigoríficos são frequentemente alvos de preocupações ambientais, ecológicas (PACHECO; YAMANAKA, 2006) e para a saúde do trabalhador (MARRA, 2019).

Os trabalhadores de frigoríficos, também conhecidos como magarefes, desempenham a trajetória de processamento da carne para sua comercialização, processo que se inicia no abate e passa por etapas como desossa, cortes, salga, dessecação, tratamento de seus subprodutos, entre outros (MARRA, 2019). Em sua tese, Marra (2019) descreve os diferentes riscos envolvidos dentre essas etapas e as cargas sofridas pelos trabalhadores, e a forma com que tais afetam sua saúde. Aqui destaca-se, além dos riscos de acidente (GOLLAC, 2005), os frequentes distúrbios musculoesqueléticos como Lesão por Esforço Repetitivo (LER) e os Distúrbios Osteomusculares Relacionados ao Trabalho (DORT) em geral, que são a causa mais comum de doença entre esses trabalhadores (JAKOBI et al., 2015). Os trabalhadores de frigoríficos ocuparam a segunda posição em acidentes e doenças e trabalhos em estudo realizado por Vasconcellos e colaboradores (2009) no Mato Grosso e lideraram o número de afastamento por motivos de doença de trabalho em levantamento do Ministério Público do Trabalho (MINISTÉRIO DO TRABALHO E EMPREGO, 2004). A saúde mental dos trabalhadores também é colocada à prova, devido à própria dinâmica do trabalho e a política de cumprimento de metas (TAVOLARO et al., 2007; IKEDO; RUIZ, 2014; MACHADO; MUROFUSE; MARTINS, 2016; GUILLAND et al., 2017; SILVEIRA; MERLO, 2017).

A produção em massa dominou a dinâmica do trabalho em frigoríficos ao longo das últimas décadas (MARRA, 2019), onde ocorreu especialização do maquinário para cada vez maior produtividade. No entanto, Marra (2019) destaca que com as máquinas, não foi somente

a produtividade que se elevou, mas também a intensidade do trabalho. Ao mesmo tempo, mesmo com maior produtividade e menor valor de mercadoria individual, as condições precárias de trabalho se mantiveram. Destaca-se a alta rotatividade entre os trabalhadores de frigoríficos, onde Heck e colaboradores (2020) mostram que em 2019, 47% das demissões em frigoríficos se deu a pedido do próprio trabalhador, cenário incomum em tempos de altas taxas de desemprego. Antunes (1995) descreve o caráter taylorista e fordista nesse modo de produção, e Antunes e Praun (2015) argumentam que tal intensificação do trabalho resulta num "exército de trabalhadores mutilados, lesionados, adoecidos física e mentalmente, muitos deles incapacitados".

No contexto da pandemia de Covid-19, os frigoríficos foram marcados por outra preocupação com a saúde. Desde os primeiros meses da pandemia em 2020, recebeu atenção o alto número de surtos da doença que ocorriam nessas instalações (FRENCH NATIONAL ACADEMY OF MEDICINE, 2020), observados em países da Europa (GUENTHER et al., 2020; MIDDLETON; REINTJES; LOPES, 2020; MODENESE et al., 2021; RIVERA ARIZA et al., 2021), Estados Unidos (DONAHUE et al., 2020; DYAL, 2020; STEINBERG et al., 2020; WALTENBURG, 2020) e no Brasil (DE CAMPOS SILVA, 2020; PINA, 2020; SILVEIRA et al., 2020; TOOGE, 2020). Há diversos fatores envolvidos na dinâmica do trabalho que favorecem a transmissão. A manutenção do ambiente frio e úmido, com baixa taxa de renovação do ar (FRENCH NATIONAL ACADEMY OF MEDICINE, 2020; PINA, 2020) é um deles, assim como o barulho no ambiente e a necessidade de comunicação, que faz com que os trabalhadores falem alto ou gritem para se comunicar, o que propicia o lançamento de aerossóis (MIDDLETON; REINTJES; LOPES, 2020). As características socioeconômicas também desempenham um papel nesse processo. Compostos por uma alta parcela de imigrantes e refugiados (FRENCH NATIONAL ACADEMY OF MEDICINE, 2020; GRANADA et al., 2021), os trabalhadores enfrentam situações precárias no transporte ao trabalho, nas condições de habitação (FRENCH NATIONAL ACADEMY OF MEDICINE, 2020) e até mesmo no acesso à saúde (GRANADA et al., 2021). Além disso, sua categoria foi mantida como essencial durante a pandemia (HECK et al., 2020; MAENO, 2021).

Os números observados por Segata (2021a) no Rio Grande do Sul (RS) chamam atenção: 5.804 casos da doença entre trabalhadores de frigoríficos foram registrados no estado entre março e setembro. No mês de junho, esse número chegou a representar 32% dos casos do estado, o que, mesmo com a possível presença de um viés pela testagem, é um número alarmante. Em Cianorte, no Paraná, até 19 de junho de 2020 193 trabalhadores de abatedouro tiveram diagnóstico da doença, o que até então representava 62% dos casos da cidade (PINA,

2020). A autora destaca também que no RS, dos 30 municípios que lideravam os números de Covid-19 no estado, 28 eram sede de frigoríficos ou cediam trabalhadores para essas empresas. Silveira e colaboradores (2020) destacam o caso de Lajeado, no RS, que entre maio e junho de 2020 permaneceu como o município com mais casos no estado, justificado pelo alto contágio através dos dois frigoríficos na cidade (CHAPARINI, 2020). Silveira e colaboradores (2020) destacam que a alta disseminação nos frigoríficos faz com que o processo de difusão da doença esperado através da hierarquia entre as cidades seja atravessado, visto que 80% dos frigoríficos de inspeção nacional estão em cidades pequenas, com menos de 100 mil habitantes, e 42% deles, naquelas com menos de 30 mil (PINA, 2020). O alto número de casos nas instalações e o descaso das empresas resultaram em preocupações para os sindicatos (MEIRELLES, 2020) e em manifestações por melhores condições de trabalho, como a ocorrida em setembro, de organização nacional, em São Paulo (REDE TVT, 2020). Outro fator preocupante quanto ao contágio é o alto fluxo de trabalhadores entre os municípios sede dos frigoríficos e suas residências, visto que muitas dessas instalações procuram mão de obra fora do município ou até fora do país (GEMELLI; CARVALHAL, 2011; HECK et al., 2020).

Altas medidas de frequência, como incidência e soroprevalência de Covid-19, foram observadas entre os trabalhadores desse grupo através de inquéritos sorológicos e estudos de monitoramento de surtos na Europa (MODENESE et al., 2021; RIVERA ARIZA et al., 2021). No Brasil, utilizando dados da previdência social, Maeno (2021) mostrou que houve um estrondoso salto nas notificações de doenças por vírus relacionadas ao trabalho em 2020, sendo que entre as ocupações externas à área da saúde, os magarefes (trabalhadores de frigoríficos) estavam entre os grupos que mais apresentaram ocorrências (MINISTÉRIO DO TRABALHO, 2021). A relação com a presença dos frigoríficos também foi levada em conta em análises geográficas e espaciais da doença. Heck e colaboradores (2020) observaram coincidência espacial entre a distribuição da Covid-19 pelos municípios do interior dos estados da região Sul e a presença de atividade frigorífica. Nascimento e colaboradores (2020) também destacaram a influência do trabalho agroindustrial para a disseminação da Covid-19 na Mesorregião Grande Fronteira Mercosul. Silveira e colaboradores (2020) apontaram o papel que não só os frigoríficos, mas também toda a rede de fluxos envolvida na cadeia de produção de carnes exerceram sobre a disseminação da doença na região de Lagos, no RS. Resultado similar foi obtido em estudo no sul e sudoeste do estado do Pará, onde Serra e Oliveira (2020) encontraram associações significativas que mostravam que o número de trabalhadores em abate de bovinos nessas regiões se relacionava de forma inversa com o índice de isolamento social e direta com o número de casos e óbitos por Covid-19.

Dessa forma, o presente estudo busca agregar aos estudos que se propõem a compreender o papel dos frigoríficos na disseminação da doença entre os municípios menores e o papel das precárias condições de trabalho como um relevante determinante da infecção e agravamento da doença. Será o primeiro estudo, até onde se sabe, a investigar associações estatísticas em nível ecológico através de modelagem estatística entre a atividade frigorífica e a distribuição da Covid-19, assim como o primeiro a contemplar o estado de São Paulo, o 4º município com maior capacidade de abate no país (ABIEC, 2018).

2.3 ANÁLISES ESPACIAIS E ESPAÇO-TEMPORAIS

A epidemiologia espacial, entre suas diversas aplicações, volta as atenções para as múltiplas e complexas formas com que se dá a relação entre a saúde e seus determinantes no espaço (LAWSON et al., 2016). Com o avanço e difusão dos sistemas de informação geográfica (SIG) e a implementação e disponibilização de métodos espaciais ao longo dos últimos 30 anos, o interesse e a aplicação de análises espaciais têm crescido em diversos campos, entre eles a epidemiologia (CARPENTER, 2011; MELIKER; SLOAN, 2011; AUCHINCLOSS et al., 2012). Auchincloss e colaboradores (2012) em uma revisão destacam os modelos de regressão espaciais em geral como um dos tópicos de maior crescimento, e ressaltam também o aumento na utilização de modelos Bayesianos. A esses últimos voltam-se as atenções no presente trabalho.

2.3.1 Modelagem Bayesiana em estudos epidemiológicos

No que se trata de mapeamento de doenças (*disease mapping*) e principalmente do estudo de suas dinâmicas no espaço e no tempo, frequentemente tem-se recorrido aos modelos estatísticos Bayesianos (BAILEY, 2001; BLANGIARDO et al., 2013; LAWSON, 2013a; LÓPEZ-QUÍLEZ, 2019). Sob a perspectiva Bayesiana, é tornada possível a incorporação de estruturas complexas e flexíveis que representem as diversas características envolvidas no processo de distribuição da doença ao longo dos territórios e do ambiente (LÓPEZ-QUÍLEZ, 2019). A ideia básica por trás dessa corrente estatística é que as incertezas são todas descritas por distribuições de probabilidade (BLANGIARDO et al., 2013), de forma que todos os valores desconhecidos e parâmetros são variáveis aleatórias que também possuem sua própria distribuição (GÓMEZ-RUBIO, 2020). A inferência através desses modelos, portanto, é

realizada ao combinar as distribuições *a priori* dos parâmetros com os dados observáveis, obtendo distribuições *a posteriori* (BLANGIARDO et al., 2013).

Além de maior clareza na quantificação das incertezas associadas, outra vantagem característica dos modelos Bayesianos é a facilidade com que se pode formalmente incluir conhecimento prévio sobre os parâmetros do modelo através de estudos anteriores ou opiniões profissionais (BLANGIARDO et al., 2013). Em estudos de mapeamento de doenças, é comum utilizar tais modelos para obter taxas de incidência ou mortalidade mais robustas do que aquelas obtidas de forma direta, visto que estas são fortemente instáveis a depender do tamanho da população em risco em cada região (RICHARDSON et al., 2004).

Em análises de contagens de ocorrências de uma doença ao longo de um território definido por áreas/regiões, é comum especificar um modelo para $Y = (y_1, \dots, y_n)$ onde y_i representa a contagem da doença em uma área i . Assume-se que cada y_i segue uma distribuição de Poisson com parâmetro de média λ_i , destrinchada em $\lambda_i = e_i \rho_i$, onde e_i é o número de ocorrências que seriam esperadas na região i . Esse valor esperado é geralmente estimado através de padronização indireta, onde pode-se considerar as estruturas etárias e de sexo das populações em risco (LAWSON, 2013b). Dessa forma, ρ_i pode ser tratado como o risco relativo da doença para a região i . Assim, especifica-se uma relação log-linear entre ρ_i e os preditores do modelo:

$$y_i \sim \text{Poisson}(e_i \rho_i) \quad (1)$$

$$\log(\rho_i) = \eta_i \quad (2)$$

Outro fator frequente em estudos epidemiológicos é a necessidade de lidar com as tendências espaciais e/ou temporais presentes nos dados, e que precisam ser levadas em conta. A partir de um modelo Bayesiano com estrutura hierárquica, é permitida a inclusão de componentes que dão conta de capturar essas correlações – os chamados efeitos aleatórios (BEST; RICHARDSON; THOMSON, 2005). Através deles, é possível capturar as estruturas espacial e temporal assim como sua interação, além de lidar com a superdispersão dos dados.

Para o componente espacial, uma especificação muito comum é a estrutura de correlação condicional autorregressiva (CAR) (BESAG, 1974). Tal estrutura é responsável pela captura da autocorrelação espacial entre as áreas, baseando-se em uma estrutura de vizinhança definida tipicamente pelas regiões que dividem fronteira. Ao lado de outro componente espacial não estruturado, cujos efeitos são modelados como independentes e identicamente distribuídos (i.i.d.), tem-se o modelo amplamente utilizado conhecido como Besag-York-Mollié (BYM) (BESAG; YORK; MOLLIE, 1991). Ao adicionar tais componentes, o preditor linear do modelo assume a seguinte forma:

$$\eta_i = \beta_0 + u_i + v_i \quad (3),$$

onde β_0 é o intercepto do modelo e u_i e v_i os efeitos espaciais estruturado (CAR) e não estruturado, respectivamente. Mais recentemente, uma reparametrização do modelo BYM foi proposta por Riebler (2016), de forma a incluir um parâmetro de precisão que modela de forma explícita a proporção de variância explicada pelos dois componentes. Tal reparametrização é conhecida como BYM2 e segue as proposições de complexidade penalizada (SIMPSON et al., 2017), o que favorece que os modelos tenham parâmetros mais claramente interpretáveis (MORRIS et al., 2019). Dessa forma, a combinação dos componentes espaciais $u_i + v_i$ passa a ser escrita como:

$$\left((\sqrt{\delta/s})u_i + (\sqrt{1-\delta})v_i \right) \sigma \quad (4),$$

onde δ regula as parcelas de variância provindas do efeito estruturado u_i e não estruturado v_i ; s é o fator de escala; e σ é o desvio padrão para os termos combinados.

Embora diversas análises espaciais considerem os casos agregados em um recorte temporal específico, há situações em que tais modelos são insuficientes para descrever padrões espaciais não constantes ao longo do tempo (ABELLAN; RICHARDSON; BEST, 2008), o que é comumente o caso para doenças infecciosas (LÓPEZ-QUÍLEZ, 2019). A estrutura hierárquica do modelo apresentada é extensível para o emprego de efeitos aleatórios temporais. Bernardinelli (1995) propôs uma extensão que permitia a captura de tendências temporais entre as áreas, mas que continha um forte pressuposto de linearidade dessa tendência. Knorr-Held (2000) assim propôs a inclusão de outros dois efeitos aleatórios: γ_t , dinamicamente estruturado através dos momentos no tempo; e ϕ_t , tratado de forma não estruturada. Tipicamente, γ_t é modelado através de uma estrutura de passeio aleatório (*Random Walk – RW*) de ordem 1 ou 2, mas pode assumir outras especificações para atender outras características como a sazonalidade (JOHNSON; RAVI; BRANEON, 2021). Dessa forma, o modelo passa a conter:

$$\eta_{it} = \beta_0 + u_i + v_i + \gamma_t + \phi_t \quad (5),$$

e as contagens passam a ser identificadas iterando pelas n áreas (identificadas pelo índice i) e d períodos no tempo (identificados pelo índice t).

Dessa forma, o modelo descrito captura as tendências temporais da doença que ocorrem sobre a região de estudo como um todo. Contudo, pode ser o caso de haver diferenças entre as tendências temporais ao longo das áreas dentro da região de estudo. Novamente, o modelo hierárquico é expansível a ponto de comportar interações espaço-tempo, o que permitiria explicar tais diferenças (BLANGIARDO; CAMELETTI, 2015). Tal situação é aprofundada na seção 2.3.3.

Por fim, frequentemente é de interesse, para além da descrição da distribuição espaço-

temporal da doença, investigar a forma com que fatores a nível ecológico se associam a essa distribuição (WAKEFIELD, 2008; WAKEFIELD; SMITH, 2016). É possível, portanto, inserir regressores ao modelo especificado, de forma a capturar essa associação entre os fatores de interesse e o desfecho. Essa inserção ocorre de forma similar aos modelos de regressão tradicionais, com a diferença que dentro dos modelos Bayesianos os coeficientes de regressão também assumem uma distribuição *a priori*, a ser especificada (BLANGIARDO; CAMELETTI, 2015). Assim, o modelo pode ser estendido para:

$$\eta_{it} = \beta_0 + \left(\sum_{m=1}^M \beta_m x_{im} \right) + \nu_i + \nu_i + \gamma_t + \phi_t \quad (6),$$

onde agora os efeitos das M variáveis de interesse, representadas por x_m , são capturados através dos coeficientes β_m . Quando exponenciados, tais efeitos podem ser interpretados como riscos relativos; e os efeitos espaciais e temporais passam a representar os riscos específicos associados a cada área e período após considerar os efeitos das variáveis x .

Essa especificação base para modelos espaço-temporais já foi amplamente utilizada para modelagem de doenças infecciosas (MUSENGE et al., 2013; NOOR et al., 2014; DA COSTA et al., 2018; KANG et al., 2018; MELLOR et al., 2018), e vem sendo utilizada em análises espaço-temporais da Covid-19 no mundo (JAYA; FOLMER, 2020; PAUL et al., 2020; JALILIAN; MATEU, 2021; JOHNSON; RAVI; BRANEON, 2021; PAUL et al., 2021; SAHU; BÖHNING, 2021) e no Brasil (BERMUDI et al., 2021; LI et al., 2021; LORENZ et al., 2021).

Reconhece-se que uma das grandes limitações dos modelos Bayesianos reside em seus aspectos computacionais. Os métodos de simulação conhecidos como *Markov Chain Monte Carlo* (MCMC) (GELMAN et al., 2014) são frequentemente usados para o ajuste de tais modelos, e embora permitam ampla flexibilidade em sua especificação, a demanda de tempo e recursos computacionais tende a ser alta para modelos mais complexos (BLANGIARDO; CAMELETTI, 2015; GÓMEZ-RUBIO, 2020), inviabilizando algumas análises. Mais recentemente, Rue, Martino e Chopin (2009) propuseram uma alternativa metodológica baseada no algoritmo de Aproximação de Laplace Aninhada Integrada (INLA), que provê vantagens computacionais e tem permitido o ajuste de uma considerável parcela de modelos Bayesianos em tempos muito menores. A tal método se dedica a próxima seção, 2.3.2.

2.3.2 INLA

O algoritmo INLA, proposto por Rue e colaboradores (2009), é um algoritmo determinístico para estimação das distribuições *a posteriori* em inferência Bayesiana, diferindo portanto dos outros métodos para ajuste baseados em simulação, como o MCMC (BLANGIARDO; CAMELETTI, 2015). Em relação a esses outros métodos, há uma mudança de foco: ao invés de estimar uma distribuição *a posteriori* conjunta multivariada, opta-se por realizar aproximações de várias distribuições *a posteriori* marginais univariadas (GÓMEZ-RUBIO, 2020). Além disso, o foco é também restringido a um conjunto de modelos específicos, aqueles que podem ser expressos como Campos Aleatórios de Markov Gaussianos (GMRF), o que já provê algumas vantagens computacionais (RUE; HELD, 2005). Uma dessas vantagens envolve o aproveitamento das propriedades das matrizes esparsas, as quais são repletas de valores nulos que não precisam ser armazenados pelo computador (BAKKA et al., 2018).

As vantagens computacionais obtidas são muito benéficas para a modelagem estatística Bayesiana, uma vez que modelos de especificação complexa para os quais antes não se conseguia estimar as distribuições *a posteriori*, agora podem ser ajustados em um dia, ou até menos. Além disso, modelos que tomavam dias para serem ajustados agora requerem tempo extremamente menor, o que permite aos pesquisadores que ajustem diferentes modelos, e realizem análises de sensibilidade em relação à especificação das distribuições *a priori* e da verossimilhança escolhida (BAKKA et al., 2018). Análises como a de Carroll e colaboradores (CARROLL et al., 2015) compararam os métodos de ajuste INLA e *OpenBUGS* (baseado em simulação e MCMC) para ajuste de modelos de Poisson para mapeamento de doenças. Os autores mostram que a vantagem de tempo e recursos que o INLA obtém sobre os outros métodos de ajuste é indiscutível, mas utilizando suas configurações padrões de *software*, há uma perda considerável na precisão da estimação das distribuições *a posteriori*. No entanto, ao utilizar diferentes especificações dos parâmetros iniciais, obtém-se resultados similares.

Uma facilidade relativa ao INLA é a sua eficiente implementação para a linguagem estatística R, chamada R-INLA (MARTINO; RUE, 2010), que tem sido amplamente utilizada (RUE et al., 2017). O pacote substitui completamente outras versões do programa INLA anteriormente disponíveis, e sua implementação computacionalmente eficiente, assim como sua interface simples e acessível, tem permitido o ajuste e aplicação de diversos modelos espaciais e espaço-temporais (BAKKA et al., 2018). De fato, a vasta maioria dos estudos espaço-temporais citados na seção anterior (JAYA; FOLMER, 2020; BERMUDI et al., 2021; JALILIAN; MATEU, 2021; JOHNSON; RAVI; BRANEON, 2021; LI et al., 2021; LORENZ et al., 2021; SAHU; BÖHNING, 2021) utilizam o R-INLA para estimação.

2.3.3 Interações espaço-tempo e coeficientes variáveis

Uma possível extensão da estrutura hierárquica dos modelos apresentados é a inclusão de termos de interação entre os componentes espaciais e temporais, permitindo assim especificidades nas tendências temporais ao longo das diferentes áreas. Apesar do modelo proposto por Bernardinelli (1995) contemplar diferenças nas tendências entre as áreas, o pressuposto de linearidade dessas tendências se torna um fator restritivo para certas situações (KNORR-HELD, 2000). Assim, tendo como base o produto de Kronecker para a obtenção das interações (CLAYTON, 1998), Knorr-Held (2000) propôs quatro formas de definir as estruturas de interação, representadas pelo termo π_{it} :

$$\eta_{it} = \beta_0 + \left(\sum_{\{m=1\}}^M \beta_m x_{im} \right) + v_i + v_i + \gamma_t + \phi_t + \pi_{it} \quad (8)$$

A interação do tipo I assume que os dois efeitos aleatórios não estruturados - v_i e ϕ_t interagem, onde assume-se que não há especificidades nas tendências temporais entre as áreas, porém sem qualquer estrutura de relação espacial ou temporal.

A interação do tipo II envolve o efeito temporal estruturado γ_t e o efeito espacial não estruturado v_i . Assim, assume-se que a tendência temporal específica de uma área i possui uma estrutura autorregressiva, mas é independente das tendências de outras regiões vizinhas.

A interação tipo III combina o efeito estruturado espacial v_i com o efeito não estruturado temporal ϕ_t . Ou seja, assume-se que as especificidades na tendência temporal em um dado momento t se relacionam entre si com uma estrutura de dependência espacial, mas que são independentes de outras especificidades em qualquer outro momento do tempo. Essa especificação é razoável se as tendências espaciais são diferentes entre os momentos do tempo, mas sem qualquer estrutura temporal.

A interação tipo IV é a mais complexa, porém mais interessante, visto que combina os dois efeitos estruturados: o espacial v_i e o temporal γ_t . Ou seja, assume-se que cada área tem especificidades na tendência temporal que possuem uma estrutura autorregressiva, e que essa estrutura não é mais independente das estruturas de outras áreas, e sim relacionadas às de seus vizinhos. Tal especificação é propícia para situações em que as tendências temporais são diferentes entre as áreas mas têm maior probabilidade de serem similares entre aquelas que são vizinhas.

Para a implementação de interações espaço-tempo, assim como a especificação dos

demais componentes do modelo, é ideal que haja plausibilidade teórica. Esse é o caso para algumas doenças infecciosas, visto que as relações entre as regiões podem variar com o tempo e as tendências temporais podem ser diferentes em diferentes partes do território. A análise espaço-temporal de Covid-19 de Johnson e colaboradores (JOHNSON; RAVI; BRANEON, 2021) implementou tal tipo de interação. Os autores argumentam, inclusive, que os efeitos relativos à interação π_{it} podem ser interpretados como “aglomerados de curta duração” da doença, ou seja, regiões que apresentaram alto ou baixo risco durante algum recorte de tempo mas não durante o período todo. No estudo citado, os autores utilizam interação do tipo I e argumentam que outros estudos utilizando outras especificações – como a interação tipo IV – contribuiriam para a compreensão da dinâmica espaço-temporal da Covid-19.

Também no contexto da Covid-19, estudos relataram a inconsistência das associações encontradas entre determinados fatores como a vulnerabilidade social e a distribuição da doença. Wang e colaboradores (2020) encontraram que tais associações variaram no espaço, e Johnson e colaboradores (2021) identificaram que o efeito da vulnerabilidade social foi diferente ao longo do tempo. Neelon e colaboradores (2021) incorporaram essa variação temporal em sua análise, identificando períodos em que maior vulnerabilidade social se apresentava com risco e como proteção, além dos pontos de inflexão. Outros fatores mostram potencial teórico para apresentarem diferentes efeitos sobre a distribuição da Covid-19 ao longo do tempo. A hierarquia urbana dos municípios, por exemplo, pode possuir diferentes efeitos uma vez que os municípios maiores e mais conectados foram se mostraram mais afetados em um primeiro momento da epidemia, e os municípios menores e do interior foram afetados posteriormente (PAUL et al., 2020; RIBEIRO et al., 2020; ALBUQUERQUE; RIBEIRO, 2021; CASTRO et al., 2021a).

Dessa forma, traz-se o conceito de que, assim como outras variáveis, o espaço e o tempo podem atuar como modificadores de efeito das variáveis (FRANCO-VILLORIA; VENTRUCCI; RUE, 2019). Dentro do contexto Bayesiano, a incorporação dessa variabilidade ao longo dessas dimensões pode ser incorporada. Os coeficientes β_m passam a ser $\beta_{m(t)}$ (no caso da variação ao longo do tempo) e têm seu valor variando para cada período t . Da mesma forma que os efeitos aleatórios, os coeficientes variáveis podem possuir uma estrutura independente ou correlacionada, como a autorregressiva. Franco-Villoria e colaboradores (2019) alertam, no entanto, que ao tratar de coeficientes variáveis, deve-se voltar atenção às distribuições *a priori* especificadas, para assim evitar que o modelo se torne muito ajustado aos dados (*overfitting*). Recomenda-se que as especificações de complexidade penalizada (SIMPSON et al., 2017; FRANCO-VILLORIA; VENTRUCCI; RUE, 2019) sejam seguidas.

Tanto as interações espaço-tempo quando os coeficientes variáveis no espaço e/ou tempo possuem implementação direta através do R-INLA.

2.4 SÍNDROME RESPIRATÓRIA AGUDA GRAVE (SRAG)

O Sistema de Informação de Vigilância Epidemiológica da Gripe (SIVEP-Gripe) é um sistema de registro e monitoramento gerido pelo Ministério da Saúde em conjunto com as Secretarias Estaduais e Municipais, e foi criado em 2009, durante a pandemia de influenza A (H1N1). O sistema registra casos de Síndrome Respiratória Aguda Grave (SRAG) e foi mantido desde então para monitoramento da síndrome e vigilância de padrões incomuns (NIQUINI et al., 2020). Um caso de SRAG é definido pela presença simultânea dos seguintes critérios: febre, mesmo que autodeclarada; tosse ou dor de garganta; dispneia ou saturação de O₂ < 95% ou desconforto respiratório; hospitalização, ou morte independentemente de hospitalização prévia (MINISTÉRIO DA SAÚDE, [s.d.]). Com a chegada da Covid-19 no ano de 2020, retirou-se a exigência do sintoma de febre para registro de um caso de SRAG. Tal decisão foi tomada por conta da alta prevalência da doença em idosos e adultos, faixa etária em que é comum não apresentar febre apesar da infecção (GOMES, [s.d.]).

Os casos de SRAG têm notificação compulsória no SIVEP-Gripe, e testes laboratoriais são realizados nos casos para identificação do agente causador da síndrome (como Influenza A, Influenza B, Vírus Sincicial Respiratório, e outros). A partir da semana epidemiológica 12 de 2020, o teste para o SARS-CoV-2 foi incluído no protocolo de vigilância (BASTOS et al., 2020).

Apesar de não incluírem todos os casos de Covid-19, dados de SRAG têm sido utilizados para monitoramento e *nowcasting* da epidemia da doença no Brasil (OBSERVATÓRIO COVID-19 BR, 2020; INFOGRIPE, 2021a). Embora dados que incluem casos leves da doença estejam também disponíveis, como pelo sistema e-SUS (<https://datasus.saude.gov.br/notifica>), estes apresentam maiores problemas quanto à qualidade dos dados. Entre eles pode-se citar altas taxas de duplicidade, diferentes acurácias entre os testes empregados, e a falta de padronização da testagem, o que introduz viés e dificulta comparações (BASTOS, 2020). Apesar da notificação compulsória, registros de SRAG podem levar certo tempo até sua disponibilidade no banco de dados, por conta do período de digitação. A classificação final do caso pode levar mais tempo para ser atualizada, devido à dependência da coleta de amostras e o período de análise laboratorial para os agentes etiológicos, se este for o caso.

Para além de monitoramento, os dados de SRAG têm sido amplamente utilizados para fins descritivos e analíticos. Logo nas primeiras semanas após a introdução do vírus da Covid-19 no Brasil, Bastos e colaboradores (2020) compararam os padrões de hospitalização naquelas últimas semanas com os padrões de anos anteriores referentes ao mesmo período. Mais posteriormente, Niquini e colaboradores (2020) realizaram estudo similar ao comparar as características das hospitalizações de SRAG causada por Covid-19 (SRAG-COVID) até maio de 2020 com as hospitalizações de SRAG por influenza (SRAG-FLU) nos anos anteriores e com as características da população em geral. Outros estudos se propuseram a descrever as hospitalizações por SRAG-COVID no Brasil de acordo com características dos pacientes, assim como variações regionais e entre os estados (HAWRYLUK et al., 2020; RANZANI et al., 2021; ZEISER et al., 2021). Análises retrospectivas buscaram descrever, através de modelagem, a distribuição das comorbidades e a variação dos riscos de mortalidade entre grupos de raça/cor (BAQUI et al., 2020; PERES et al., 2021). De Almeida e colaboradores (2020) utilizaram dados de SRAG do SIVEP-Gripe para estimação do número reprodutivo efetivo (R_t) da Covid-19 entre os Departamentos Regionais de Saúde (DRS) de São Paulo, a fim de compreender as tendências regionais e a relação com medidas não farmacológicas. Por fim, dados de SRAG e SRAG-COVID foram utilizados em análises espaço-temporais em nível agregado, onde destacou-se áreas de maior risco para hospitalização e mortalidade ao longo do tempo, assim como fatores socioeconômicos associados a esses desfechos (DE SOUZA et al., 2020; LI et al., 2021; LORENZ et al., 2021).

3 JUSTIFICATIVA

Reconhece-se a histórica importância das análises espaciais e espaço-temporais para o entendimento da dinâmica de doenças infecciosas e compreensão de fatores que se relacionam com a distribuição de tais ao longo do espaço e tempo. No contexto recente e emergente da Covid-19, o presente estudo contribui para a descrição da distribuição da doença pelo estado mais populoso do Brasil e onde foi detectado o primeiro caso confirmado da doença no país, São Paulo, ao longo de 18 meses desde a sua introdução. De forma complementar, propõe-se somar à literatura que descreve as variações de risco entre áreas de diferentes contextos socioeconômicos e a possível modificação desses efeitos ao longo do tempo.

No Brasil e no mundo, já observou-se o elevado risco de infecção pelo SARS-CoV-2 entre o grupo de trabalhadores de frigoríficos, e estudos em estados da região Norte e Sul do Brasil apontaram coincidência espacial entre a disseminação da doença pelo interior dos estados e a presença dessas instalações. Visto isso, o presente estudo é o primeiro que se propõe a quantificar através de modelagem estatística o efeito, em nível ecológico, da presença de frigoríficos sobre a distribuição da Covid-19 em São Paulo, estado de 4ª maior capacidade de abate do país.

4 OBJETIVOS

4.1 OBJETIVO GERAL

Estudar a distribuição espaço-temporal de hospitalizações e óbitos por Covid-19 no estado de São Paulo entre março de 2020 e agosto de 2021, verificando a associação com a presença de frigoríficos e outras variáveis socioeconômicas e demográficas.

4.2 OBJETIVOS ESPECÍFICOS

1. Realizar análise exploratória utilizando diferentes escalas espaciais e temporais para os desfechos, verificando a existência de padrões.
2. Verificar associação da distribuição de Covid-19 com a presença de frigoríficos e demais covariáveis através de modelos espaço-temporais.
3. Identificar áreas e períodos de alto e baixo risco a partir dos modelos ajustados.

5 METODOLOGIA

5.1 DESENHO DO ESTUDO

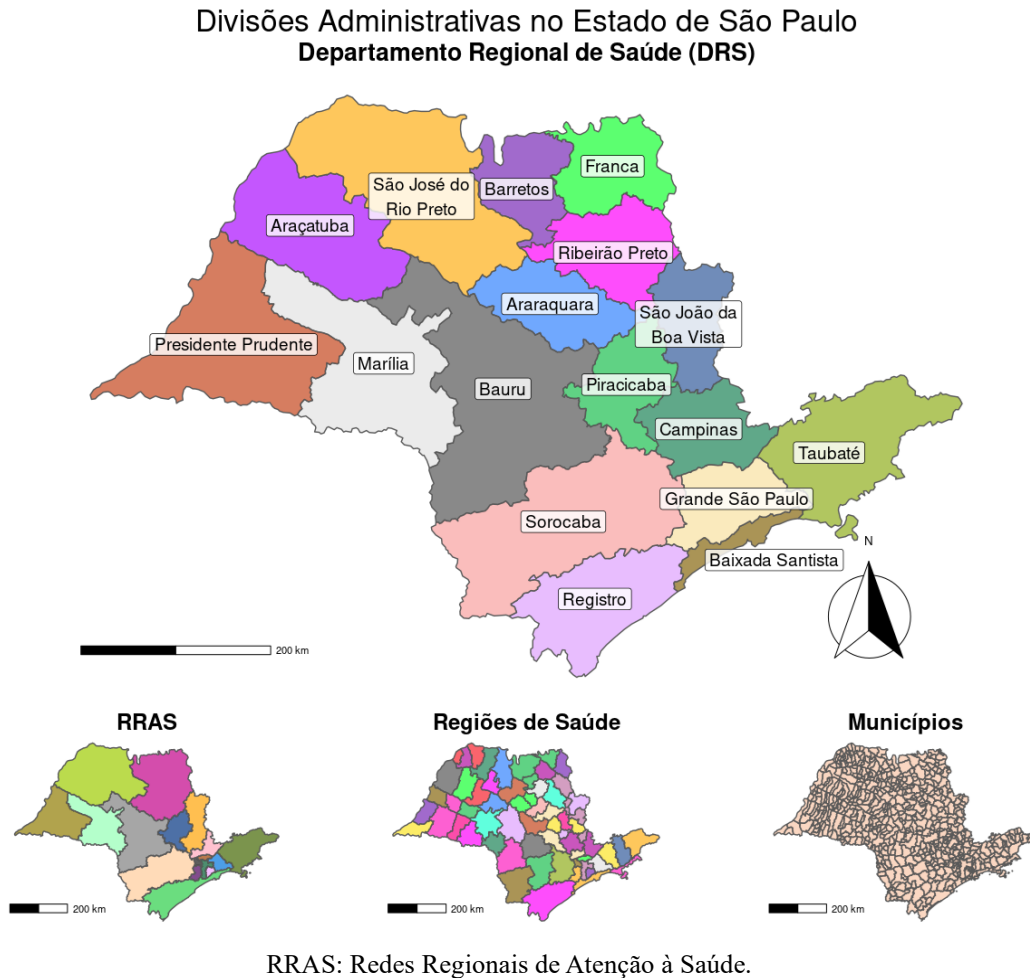
O estudo possui desenho ecológico analítico, e tem os municípios do estado de São Paulo como sua menor unidade espacial de análise. Outras unidades foram trabalhadas, como as regiões de saúde e os Departamentos Regionais de Saúde (DRS), de menor resolução espacial. Utilizou-se o mês como principal unidade temporal de análise, mas as semanas epidemiológicas (SEs) foram utilizadas em algumas situações para maior resolução temporal.

Trabalhou-se com dois desfechos principais: os casos e óbitos por SRAG-COVID. Para fins de explicação da distribuição do desfecho, covariáveis relativas à situação socioeconômica e demográfica, vulnerabilidade social e hierarquia urbana dos municípios foram consideradas. Tais variáveis também atuaram como fatores de controle para quantificação do efeito da presença de frigoríficos sobre os desfechos.

5.2 REGIÃO DO ESTUDO

O estado de São Paulo é constituído de 645 municípios, 17 Departamentos Regionais de Saúde (DRS), 17 Redes Regionais de Atenção à Saúde (RRAS) e 63 regiões de saúde (Figura 1). Pertencente à região Sudeste do país, o estado tem área territorial de 248.219,481 km² (IBGE, 2020) e população estimada para 2020 de 46.289.333 habitantes (IBGE, 2020), sendo o mais populoso do país.

Figura 1: Regionalização do Estado de São Paulo. Elaboração Própria.



O DRS “Grande São Paulo” - equivalente à Região Metropolitana do estado, concentra quase metade (46,6% - 21.571.281 habitantes) (IBGE, 2018a) da população do estado, distribuída em 39 municípios.

5.3 PERÍODO DO ESTUDO

O período de estudo foi definido entre os meses de março de 2020 e agosto de 2021 (12^a SE de 2020 à 34^a SE de 2021), de forma a contemplar 18 meses de estudo, ou 73 semanas epidemiológicas. Foi apenas a partir da 12^a semana epidemiológica de 2020 que os testes laboratoriais para o SARS-CoV-2 foram incluídos no protocolo de vigilância para a SRAG, que compõe o conjunto de dados utilizados neste estudo (descrito na seção 5.4.1). A data de fim do estudo é anterior à data de atualização dos dados utilizados, que ocorreu em 30 de setembro de 2021. Os registros relativos ao mês de setembro não foram incluídos pois devido ao atraso de

notificação e digitação grande parte dos casos do período ainda não estariam registrados (BASTOS, 2020; INFOGRIPE, 2021b).

5.4 DADOS E VARIÁVEIS

5.4.1 Desfecho

A partir de registros de SRAG, foram construídas as duas variáveis de desfecho: casos e óbitos por SRAG causadas pela Covid-19 (SRAG-COVID). É importante destacar que os casos de SRAG-COVID incluem os óbitos, além dos casos que foram hospitalizados e se recuperaram.

Casos de SRAG têm notificação compulsória e são notificados no Sistema de Informação e Vigilância Epidemiológica da Gripe (SIVEP-Gripe). Os dados de SRAG podem ser obtidos de forma aberta através da plataforma *OpenDATASUS* (<https://opendatasus.saude.gov.br/dataset/bd-srag-2020> e <https://opendatasus.saude.gov.br/dataset/bd-srag-2021>).

O SIVEP-Gripe foi criado em 2009 durante a pandemia de Influenza A (H1N1) e foi mantido para monitoramento da síndrome e vigilância de padrões incomuns (NIQUINI et al., 2020).

Um caso de SRAG-COVID foi definido como um caso hospitalizado ou óbito, independente de hospitalização prévia, de SRAG com classificação final de Covid-19 (“CLASSI_FIN” = 5).

Um óbito por SRAG-COVID foi definido como um óbito por SRAG, independente de hospitalização prévia, com classificação final de Covid-19 (“CLASSI_FIN” = 5). Para construir essa variável foram selecionados somente os registros com o campo “EVOLUCAO” = 2.

A definição de SRAG pelo Ministério da Saúde se dá pela presença simultânea de quatro critérios: febre, mesmo que autodeclarada (critério este que deixou de ser obrigatório com a chegada da Covid-19 (GOMES, [s.d.])); tosse ou dor de garganta; dispneia ou saturação de O₂ < 95% ou desconforto respiratório; hospitalização, ou morte independentemente de hospitalização prévia (MINISTÉRIO DA SAÚDE, [s.d.]).

Os registros de hospitalização são individuais e possuem mais de 80 campos de informação, entre eles dados do paciente (idade, sexo, raça/cor, escolaridade, entre outros); datas referentes à internação, primeiros sintomas, coleta de exames, evolução, e outras; município de residência do paciente e de internação; presença de sintomas; fatores de risco; exames, e outros. Os casos de SRAG são testados laboratorialmente para identificação do

agente causador da síndrome. O campo “CLASSI_FIN” informa a classificação final do caso. Este campo pode levar algum tempo para ser atualizado, por depender do tempo de análise laboratorial e digitação da atualização. Do início do período do estudo até 03 de maio de 2021, dentre os casos com resultado laboratorial positivo para algum vírus respiratório, 97,2% se referiam ao SARS-CoV-2 (INFOGRIPE, 2021b).

Para este estudo foram utilizados casos e óbitos por SRAG-COVID com UF de residência de São Paulo (“SG_UF” = “SP”). Os registros individuais foram agregados de acordo com o município de residência do paciente (“CO_MUN_RES”). Diferentes agregações temporais foram utilizadas: por mês e por semana epidemiológica. As referências temporais foram as datas de primeiros sintomas (“DT_SIN_PRI”) para a variável relativa aos casos e a data de evolução (“DT_EVOLUCA”) para os óbitos.

5.4.2 Covariáveis

A inclusão de variáveis que possivelmente contribuem para a explicação da distribuição de casos e óbitos por SRAG-COVID se deu com base em um modelo teórico elaborado. O modelo se propôs, primeiramente, a caracterizar amplas dimensões as quais se relacionam com algum dos estágios da doença: infecção, hospitalização e/ou óbito por Covid-19. Em seguida, listou-se uma parcela de fatores em nível ecológico que representam cada uma das dimensões. A partir disso, buscou-se a inclusão de um conjunto parcimonioso de variáveis que sumarizassem as relações envolvidas nesse processo complexo de determinação de casos e óbitos por SRAG-COVID nos municípios. Além do potencial de explicação, tais variáveis também atuaram como fatores de controle para a quantificação do efeito da presença de frigoríficos sobre os despechos.

A partir desse modelo teórico, descrito na seção 6.1, optou-se pela inclusão do seguinte conjunto de variáveis: o índice socioeconômico GeoSES, o índice de vulnerabilidade social (IVS), a hierarquia urbana dos municípios, a proporção de idosos e o percentual de população SUS dependente.

5.4.2.1 GeoSES

O GeoSES é um índice composto desenvolvido por Barrozo (BARROZO et al., 2020) que dimensiona o contexto socioeconômico em escalas federal (GeoSES-BR), estadual (GeoSES-UF) e intramunicipal (GeoSES-IM) no Brasil. Ele é criado a partir de variáveis do

Censo Demográfico brasileiro de 2010 (IBGE), incluindo questões do indivíduo e de sua residência. Seu desenvolvimento objetivou uma alternativa ao Índice de Desenvolvimento Humano (IDH) em análises na área da saúde, uma vez que este último inclui a longevidade em sua composição, o que pode gerar redundância em análises com desfechos de saúde.

O índice possui sete componentes: educação, mobilidade, pobreza, riqueza, renda, segregação e privação material. Seu cálculo é resultado da aplicação sucessiva de análises de componentes principais (PCA). As variáveis consideradas em cada dimensão se encontram no Anexo A. Primeiramente, um PCA em cada dimensão é realizado a fim de determinar as variáveis mais explicativas em cada uma delas, de acordo com seus coeficientes. Com as variáveis selecionadas, outro PCA é realizado e são retiradas as variáveis com contribuição menor do que a média. Após esse segundo recorte de variáveis, um último PCA é realizado e a primeira componente resultante define o GeoSES. O índice é então normalizado para o intervalo de -1 a 1, e os limites representam respectivamente o pior e o melhor contexto socioeconômico na escala analisada. Portanto, um índice GeoSES não tem interpretação por si só; seu significado se dá em termos de comparação, onde expressam-se as diferenças relativas de situação socioeconômica entre as regiões.

A inclusão do GeoSES buscou representar os fatores envolvidos na dimensão “Econômico/Social” do modelo teórico (seção 6.1), visto que sumariza em um único índice diversos fatores listados para tal dimensão – como segregação, educação, privação e renda. O índice também pode ser obtido através da plataforma OpenDATASUS (https://opendatasus.saude.gov.br/pt_PT/dataset/geoses), e foi utilizado nas análises em sua forma composta (índice geral), sem necessidade de normalização.

5.4.2.2 Índice de Vulnerabilidade Social (IVS)

O Índice de Vulnerabilidade Social (IVS) busca caracterizar situações de exclusão e vulnerabilidade social no território brasileiro (IPEA, 2015). Proposto pelo Instituto de Pesquisa Econômica Aplicada (IPEA), o IVS não se apresenta como uma alternativa ao IDH (ou ao GeoSES) mas sim como um complemento, de forma que representa a falta de oferta de bens e serviços públicos que deveriam ser direito a todo cidadão. O índice é composto por três dimensões: “infraestrutura urbana”, “capital humano” e “renda e trabalho”.

Infraestrutura urbana se refere à mobilidade urbana e a condições de acesso aos serviços de saneamento básico, como abastecimento de água e esgoto e coleta de lixo. O capital humano envolve o potencial de inclusão social atual e futura, através dos aspectos de saúde e

educação. A dimensão de renda e trabalho envolve indicadores relacionados à insuficiência e também ao estado de insegurança de renda, como desocupação dos adultos e presença de trabalho infantil. As variáveis incluídas em cada dimensão e seus pesos se encontram no Anexo B. O IVS final é uma média aritmética sem pesos de suas três dimensões, e varia de 0 a 1, onde a vulnerabilidade social aumenta conforme o índice se aproxima de 1. Um $IVS > 0,5$ já é considerado muito alto, já que reflete a presença considerável de diversas situações de vulnerabilidade.

Visto seu objetivo e composição, julgou-se que o IVS representa, de forma sumarizada, a dimensão “Habitação e Saneamento” do modelo teórico (seção 6.1), que também diz respeito a falta de acesso a direitos e condições básicos. O índice municipal pode ser obtido diretamente da página do IVS do IPEA (<http://ivs.ipea.gov.br/index.php/pt/biblioteca>). Ao contrário do GeoSES, o IVS possui uma interpretação própria. O Atlas de Vulnerabilidade Social (IPEA, 2015) sugere a seguinte leitura do índice: vulnerabilidade social muito baixa (0-0,2); baixa (0,2-0,3); média (0,3-0,4); alta (0,4-0,5); ou muito alta (0,5-1). Durante as análises, utilizou-se o índice em sua forma bruta e também de forma categorizada, seguindo as faixas de vulnerabilidade descritas. No entanto, dada a distribuição desbalanceada do índice entre as categorias e a baixa presença de municípios com vulnerabilidade alta no estado de São Paulo, optou-se pela categorização dicotômica entre municípios com vulnerabilidade baixa (muito baixa ou baixa) e aqueles com vulnerabilidade média ou alta (média, alta ou muito alta).

5.4.2.3 Hierarquia urbana

A distribuição de casos e óbitos pela Covid-19 no Brasil se deu, desde sua introdução no país, de forma heterogênea, onde observou-se distintas e concorrentes epidemias da doença no país (CASTRO et al., 2021a). No estado de São Paulo, a capital, os grandes centros urbanos e os municípios mais conectados foram afetados em um primeiro momento (DE SOUZA et al., 2020; FORTALEZA et al., 2020a; CASTRO et al., 2021a), e os municípios menos populosos posteriormente (DE SOUZA et al., 2020; ALBUQUERQUE; RIBEIRO, 2021). Assim, o modelo teórico elaborado (seção 6.1) apresenta como uma importante dimensão na determinação de novos casos e hospitalizações por Covid-19 a “demografia e conectividade do município”. Tal dimensão envolve fatores como o grau de urbanização, a conectividade, a estrutura etária, a densidade demográfica e as atividades econômicas. Assim, buscou-se a construção de uma variável que sumarizasse tais características, classificando os municípios de acordo com sua conectividade e hierarquia urbana.

Para isso, tomou-se como motivação a classificação proposta no estudo de Fortaleza (2020b), onde apresentou-se uma categorização dos municípios de São Paulo baseada em duas classificações do Instituto Brasileiro de Geografia e Estatística (IBGE): a classificação e caracterização dos espaços rurais e urbanos no Brasil (IBGE, 2017) e as regiões de influência (REGIC). A REGIC se propõe a classificar os municípios e arranjos populacionais em função das relações de influência que exercem sobre os demais, considerando a atratividade de tais em termos de atividades econômicas e suprimento de bens e serviços (IBGE, 2018b). Ambas as classificações podem ser obtidas de forma aberta através da página do IBGE (<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/15790-classificacao-e-caracterizacao-dos-espacos-rurais-e-urbanos-do-brasil.html> e <https://www.ibge.gov.br/geociencias/cartas-e-mapas/redes-geograficas/15798-regioes-de-influencia-das-cidades.html>). A partir de tais, elaborou-se uma variável intitulada “Hierarquia Urbana”, onde classificou-se os 645 municípios do estado em quatro categorias: (a) metrópoles (45 municípios); (b) capitais regionais (104 municípios); (c) municípios urbanos de menor influência regional (198 municípios); e (d) municípios rurais (298 municípios), conforme esquematizado no Quadro 1.

Quadro 1: Esquema para categorização dos municípios em relação à hierarquia urbana.

Classificação inspirada no trabalho de Fortaleza et al. (2020b).

Hierarquia Urbana	Classificações REGIC (IBGE, 2018b)	Tipologias Urbano/Rural (IBGE, 2017)
Metrópole	Grande Metrópole Nacional; Metrópole.	Todas.
Capital Regional	Capitais Regionais A, B e C.	
Município Urbano	Centros Sub-regionais A e B,	Urbano.
Município Rural	Centros de Zona A e B, e Centros Locais.	Intermediário adjacente, rural adjacente.

REGIC: Regiões de influência.

Fontes: IBGE (2017) e IBGE (2018b).

A variável Hierarquia Urbana se propõe, portanto, a sumarizar os fatores envolvidos na dimensão “demografia e conectividade”, já que considera os graus de urbanização,

conectividade e fluxo de atividades econômicas, abordados pelas duas classificações.

5.4.2.4 Proporção de idosos

Desde o início da pandemia de Covid-19, estudos observacionais têm descrito as diferenças de risco de hospitalização e óbito pela doença entre os grupos etários, onde a população idosa apresenta maior risco (DE SOUZA et al., 2020; NIQUINI et al., 2020; RANZANI et al., 2021). Visto que os municípios diferem em sua estrutura etária e na proporção de população idosa (RIBEIRO et al., 2020), tal fator deve ser levado em consideração nas análises. Dessa forma, obteve-se os dados relativos ao percentual da população estimada nos municípios pertencente à faixa etária de 60 anos ou mais, disponibilizados de forma livre e irrestrita pelo Sistema SEADE (<https://populacao.seade.gov.br/>). Foram obtidos os registros mais recentes, relativos ao ano de 2020, e a variável foi utilizada em sua forma bruta (percentual) nas análises.

5.4.2.5 População SUS dependente

Através do modelo teórico elaborado (seção 6.1), identificou-se a influência de fatores relativos aos serviços de saúde sobre as hospitalizações e óbitos por Covid-19 nos municípios. Embora esses fatores – como número de leitos SUS por habitante, percentual da população SUS dependente, distância média até a unidade de saúde mais próxima, entre outros – estejam fortemente condicionados à situação socioeconômica dos municípios, optou-se pela inclusão de uma variável pertencente à tal dimensão. Dessa forma, obteve-se o percentual estimado da população SUS dependente em cada município, referente ao ano de 2020. Tal valor é estimado a partir da saúde suplementar, e disponibilizado para livre acesso através da matriz de indicadores de saúde para atenção básica, na página da Secretaria de Estado da Saúde (https://tabnet.saude.sp.gov.br/deftohtm.exe?tabnet/ind47b_matriz.def). A variável também foi utilizada em sua forma bruta (percentual).

5.4.2.6 Frigoríficos

Para além da explicação da distribuição de casos e óbitos por Covid-19 nos municípios através das variáveis apontadas pelo modelo teórico, o presente estudo também objetiva a quantificação do efeito da presença de frigoríficos sobre os desfechos, quando condiciona-se

pelas mesmas variáveis e pelas estruturas de correlação espacial e temporal. Para a incorporação de tal fator nas análises, foram utilizados dados da Relação Anual de Informações Sociais (RAIS).

A RAIS é um relatório anual preenchido por pessoas jurídicas, tratando de relações trabalhistas (MINISTÉRIO DO TRABALHO, 2016) e é uma fonte reconhecida de informações sobre emprego formal no país (DOS SANTOS et al., 2018). No relatório, constam informações como o número de empregados, admissões, demissões, natureza e tamanho do estabelecimento, remuneração média, município de localização do estabelecimento e de trabalho. Assim como realizado por Heck e colaboradores (2020), Serra e Oliveira (2020) e Silveira e colaboradores (2020), é possível obter a relação de municípios onde há atividade de frigoríficos e a quantidade de trabalhadores, permitindo a inclusão dessa informação nas análises espaço-temporais.

A descrição da atividade realizada se dá pelos códigos da Classificação Nacional de Atividades Econômicas (CNAE). Os códigos relacionados à atividade frigorífica estão no Quadro 2.

Quadro 2: Códigos de Subclasse CNAE 2.0 Relacionados à Atividade Frigorífica (IBGE, 2015)

Subclasse CNAE 2.0	Descrição da Atividade Econômica
1011201	Frigorífico - Abate de Bovinos
1011202	Frigorífico - Abate de Equinos
1011203	Frigorífico - Abate de Ovinos e Caprinos
1011204	Frigorífico - Abate de Bufalinos
1011205	Matadouro - Abate de Reses Sob Contrato, Exceto Abate de Suínos
1012101	Abate de Aves
1012102	Abate de Pequenos Animais
1012103	Frigorífico - Abate de Suínos
1012104	Matadouro - Abate de Suínos Sob Contrato
1013901	Fabricação de Produtos de Carne
1013902	Preparação de Subprodutos do Abate

Fonte: IBGE, 2015.

Os microdados da RAIS estão disponíveis de forma aberta na página do Programa de Disseminação das Estatísticas do Trabalho (PDET, <http://pdet.mte.gov.br/microdados-rais-e-caged>). Foram obtidos os registros relativos ao ano de 2020, para o estado de São Paulo. Após realizar o recorte dos registros filtrando pelas subclasses expressas no Quadro 2, pode-se calcular uma razão entre o número de trabalhadores envolvidos em atividade frigorífica no município e o número total de trabalhadores. Essa razão já poderia ser utilizada nas análises como uma variável contínua; no entanto, a mesma possui distribuição seja acentuadamente assimétrica, dada a alta concentração de valores muito baixos. Assim, propôs-se a categorização dessa razão para uma variável dicotômica, de forma a separar os municípios entre aqueles que concentram atividade frigorífica e aqueles que não. Municípios que possuíam ao menos 1 trabalhador de frigorífico a cada 10.000 trabalhadores registrados na RAIS foram considerados como municípios com atividade frigorífica. Os demais foram classificados como municípios sem presença de frigoríficos. Estabeleceu-se esse ponto de corte de forma arbitrária, a fim de obter uma proporção de ao menos 1:5 entre as duas categorias.

5.5 ANÁLISES ESTATÍSTICAS

5.5.1 Análise exploratória

A etapa exploratória objetivou a visualização de padrões gerais da distribuição de SRAG-COVID ao longo do estado e do tempo, atentando-se a municípios e DRS de destaque em cada ano e mês de estudo para os dois desfechos. A construção de mapas coropléticos e de séries temporais foi amplamente realizada. Mapas das taxas de casos e óbitos por SRAG-COVID por 100.000 habitantes no período foram elaborados, em recortes de mês e ano, permitindo a observação da mudança dessa distribuição espacial ao decorrer do tempo. Para os pontos de corte para categorização das taxas, foram utilizados as quebras naturais de Jenks (JENKS, 1967), método comumente utilizado na elaboração de mapas estatísticos que busca a redução da variância intra-categoria e maximização da variância entre as categorias.

Para observação mais nítida de padrões espaciais e tratamento das taxas flutuantes - valores extremos devidos à baixa população em municípios menores - as taxas foram suavizadas espacialmente. A suavização se deu através do estimador Bayesiano empírico local (WALLER; GOTWAY, 2004), onde informação complementar sobre a taxa em uma região é extraída através das taxas de seus vizinhos - neste caso, os vizinhos por contiguidade - e

ponderada segundo o tamanho de suas populações.

A fim de detectar aglomerados de altos valores para casos e para e óbitos por SRAG-COVID assim como municípios *outliers*, foram calculados os índices de Moran local (indicadores locais de associação espacial – LISA) (ANSELIN, 1995). Ao combinar os valores obtidos de autocorrelação local e sua significância estatística, pôde-se apresentar os resultados através dos chamados *LISA maps* (ANSELIN, 1998), onde identifica-se aglomerados com significância estatística que possuem taxas acima da média (“Alto-alto”) ou abaixo (“Baixo-baixo”), bem como municípios destoantes de seus vizinhos (“Alto-baixo” ou “Baixo-alto”). Ao visualizar tais mapas em recortes de tempo anuais e mensais, buscou-se identificar áreas de constante concentração de altas taxas de casos e/ou óbitos por SRAG-COVID assim como aglomerados de curta duração.

As covariáveis contínuas tiveram sua distribuição estudada através de histogramas. Gráficos de dispersão e gráficos de barras por grupo foram utilizados para visualizar a relação entre variáveis contínuas e entre uma contínua e discreta, respectivamente. Mapas coropléticos das covariáveis também foram confeccionados.

A fim de tomar um breve conhecimento da relação entre as covariáveis e o desfecho, gráficos de barra e séries temporais foram elaboradas para visualizar a variação das taxas de incidência e mortalidade em cada grupo ao longo do tempo. As variáveis contínuas foram categorizadas para essa etapa. No caso das séries temporais, a suavização temporal através do método *Loess* (CLEVELAND; GROSSE; SHYU, 1992) foi empregada para facilitar a distinção de padrões temporais entre os grupos.

5.5.2 Modelagem

Para estimação da distribuição espaço-temporal e identificação da associação entre as covariáveis e os dois desfechos – casos e óbitos por SRAG-COVID – foram utilizados modelos estatísticos sob a perspectiva Bayesiana. Os desfechos foram modelados separadamente.

Para os dois desfechos, assume-se que y_{it} , que representa a contagem de casos ou óbitos por SRAG-COVID no município i em um determinado mês t , segue uma distribuição de Poisson com média $\lambda_{it} = E_i \rho_{it}$, de forma que $y_{it} \sim Poisson(E_i \rho_{it})$. E_i representa a contagem esperada de casos ou óbitos para aquele município, sob a suposição de homogeneidade espacial e temporal do processo. ρ_{it} pode assim ser interpretado como o risco relativo específico para o município i em um mês t . O valor esperado E_i é igual para todos os meses, e é calculado somente em função da população em risco nos municípios, da seguinte forma (LAWSON,

2013b):

$$r = \frac{(\sum_{i=1}^n \sum_{t=1}^{|T|} Y_{it}) / |T|}{\sum_{i=1}^n Pop_i}$$

(9a), e

$$E_i = Pop_i \times r \text{ (9b),}$$

sendo n é o número total de municípios na região de estudo, $|T|$ o total de meses, e Pop_i a população em risco no município i , estimada para 2020. Especificou-se uma relação log-linear entre o risco relativo e os preditores do modelo:

$$\log(\rho_{it}) = \eta_{it} \text{ (10),}$$

para a qual η_{it} é o preditor linear.

O processo de modelagem se iniciou pela definição de uma estrutura para os modelos, ainda sem considerar as covariáveis. Tal estrutura é descrita por seus componentes espacial e temporal, que são combinações de efeitos aleatórios. Esses efeitos podem assumir diferentes especificações, e têm a função de condicionar o ajuste do modelo às estruturas de correlação espaciais e temporais presentes nos dados. Assim, buscou-se obter uma combinação que capturasse a distribuição espaço-temporal dos desfechos, enquanto ainda mantinha sentido teórico sobre o processo.

O modelo inicial era composto apenas por efeitos aleatórios não estruturados (independentes e identicamente distribuídos – i.i.d.), tanto no espaço (v_i) quando no tempo (ψ_t), da seguinte forma:

$$\eta_{it} = \beta_0 + v_i + \psi_t \text{ (11)}$$

De forma iterativa, incluiu-se efeitos espaciais e temporais estruturados. O efeito estruturado espacial (ϕ_i) assumiu a especificação autorregressiva condicional (CAR) (BESAG, 1974), onde a captura da correlação espacial baseia-se em uma matriz de vizinhança definida (BIVAND; PEBESMA; GÓMEZ-RUBIO, 2008). Para esse estudo, tal matriz foi definida com base na contiguidade: um município i e outro município j eram considerados vizinhos se compartilhavam uma fronteira geográfica. Assim, testou-se um componente espacial somente com o efeito estruturado CAR (ϕ_i) e também com a combinação entre o estruturado e não estruturado ($\phi_i + v_i$), que corresponde ao modelo BYM (BESAG; YORK; MOLLIE, 1991). Uma reparametrização do modelo BYM, conhecida como BYM2 (RIEBLER et al., 2016) também foi testada. Esta última conta com uma reparametrização que estima de forma explícita a proporção da variância explicada por cada componente.

Os efeitos estruturados temporais (γ_t) testados foram os efeitos de passeio aleatório (“*random walk*” - RW) de ordem 1 e 2 (RW1 e RW2). De forma similar ao componente espacial, também avaliou-se combinações entre os dois efeitos, estruturado e não estruturado. Dessa forma, a estrutura do modelo com todos esses efeitos é dada por:

$$\eta_{it} = \beta_0 + \phi_i + v_i + \gamma_t + \psi_t \quad (12).$$

Para cada combinação entre os efeitos, avaliou-se: a precisão de seus hiperparâmetros; a contribuição de cada componente para explicação da variância do desfecho; seus intervalos de credibilidade de 95%; e o Critério de Informação de Deviance (DIC) do modelo, métrica que busca quantificar a qualidade do ajuste.

Levando em conta os diferentes e complexos cenários da doença ao longo do estado e suas concorrentes epidemias (CASTRO et al., 2021a), optou-se por inserir termos de interação espaço-tempo, seguindo o que é apresentado por Blangiardo e Cameletti (2015). As interações espaço-tempo permitem que as tendências temporais possuam especificidades ao longo do território, e não sejam definidas apenas por uma tendência temporal global. Testou-se, portanto, os quatro tipos de interação apresentados por Knorr-Held (2000). No entanto, optou-se por testar diferentes unidades espaciais de análise para os componentes de interação (δ_{it}), a fim de trazer maior sentido teórico e maior parcimônia ao modelo. Hipotetiza-se que a situação da epidemia dentro de cada região foi semelhante, não sendo assim necessário um termo de interação para cada combinação de município e mês - o que poderia tornar o modelo específico demais. Assim, testou-se também interações espaço-tempo ao nível de DRS-mês e região de saúde-mês. Dessa forma, o modelo passa a ser:

$$\eta_{it} = \beta_0 + \phi_i + v_i + \gamma_t + \psi_t + \delta_{kt} \quad (13),$$

para a qual δ_{kt} representa a interação espaço-tempo na região k no mês t . Cada um dos municípios i 's tem um único índice k correspondente.

Apesar dos efeitos aleatórios lidarem com a superdispersão (LAWSON, 1999), verificou-se se houve melhoras no ajuste ao trocar a verossimilhança para binomial negativa. Por conta do alto número de zeros para casos e principalmente óbitos nos primeiros meses da epidemia, as verossimilhanças infladas em zero - Poisson inflada em zero (ZIP) e binomial negativa inflada em zero (ZINBI) - também foram verificadas.

Após definir os componentes aleatórios e a verossimilhança do modelo, as covariáveis foram incluídas, com coeficientes fixos no espaço e no tempo:

$$\eta_{it} = \beta_0 + (\sum_{m=1}^M \beta_m x_{im}) + \phi_i + v_i + \gamma_t + \psi_t + \delta_{kt} \quad (14),$$

para a qual o valor da m -ésima variável na região i se dá por x_{im} . Os coeficientes

estimados β_m para cada variável quando exponenciados podem ser interpretados em termos de risco relativo, correspondente a cada variável.

Após o ajuste de modelos simples, com apenas uma variável, modelos múltiplos foram ajustados através de inclusão sequencial das variáveis, de forma que a variável relacionada aos frigoríficos foi a última a entrar no modelo. Mesmo que a inclusão de uma variável não implicasse em uma redução no DIC, optou-se por sua manutenção no modelo, visto a importância para a explicação do desfecho constatada pelo modelo teórico. Só optou-se pela remoção em situações de correlação entre as variáveis, verificada pela análise exploratória, ou caso a inclusão da variável implicasse em drástica redução na precisão dos hiperparâmetros ou prejudicasse a estimação dos efeitos.

Visto a plausibilidade teórica do efeito das variáveis sobre o desfecho ser diferente ao longo do tempo, foi explorada a possibilidade de inclusão de coeficientes variáveis nessa dimensão, seguindo as recomendações de Franco-Villoria e colaboradores (2019). As estruturas testadas para captura de tal variação temporal foram a estruturada através de passeio aleatório de ordem 2 (RW2) e não estruturada (i.i.d.).

Para a interpretação dos resultados, obteve-se os riscos relativos relacionados a cada município e mês, através da exponenciação do preditor linear ρ_{it} . Uma prática comum para a interpretação dos riscos estimados é a sua representação na forma de probabilidades excedentes (RICHARDSON et al., 2004), como a probabilidade de que cada área apresente risco > 1 naquele momento. Com a exponenciação dos efeitos aleatórios obtém-se uma perspectiva da tendência temporal da epidemia, tanto de uma forma global sobre o estado, quanto sobre cada região de saúde, ao considerar as interações. Por fim, riscos relativos relacionados à cada covariável foram obtidos através da exponenciação das médias de seus respectivos coeficientes e seus intervalos de credibilidade.

Todos os modelos foram ajustados utilizando o algoritmo determinístico INLA (RUE; MARTINO; CHOPIN, 2009), utilizando *prioris* não informativas.

5.5.3 Software

Todas as etapas da análise estatística serão realizadas através da linguagem estatística R (R DEVELOPMENT CORE TEAM, 2010), em sua versão 4.1.1, e no ambiente computacional Rstudio (ALLAIRE, 2012), versão 1.4.1717. O tratamento e limpeza dos dados foi realizado utilizando funções dos pacotes “tidyr” (WICKHAM, 2017) e “dplyr” (WICKHAM et al., 2014). A malha espacial foi obtida com o pacote “geobr” (PEREIRA;

GONÇALVES, 2019). Para tratar da matriz de vizinhança, estatísticas de autocorrelação espacial e suavização espacial, foi utilizado o pacote “spdep” (BIVAND et al., 2015). “sf” (PEBESMA, 2018) e “ggplot2” (WICKHAM, 2011) foram utilizados para elaboração de mapas e demais visualizações gráficas. Por fim, o ajuste dos modelos espaço-temporais se deu através do pacote “R-INLA” (MARTINO; RUE, 2010), e métricas relativas aos modelos foram obtidas com o pacote “INLAOutputs” (BAQUERO, 2018).

5.6 ASPECTOS ÉTICOS

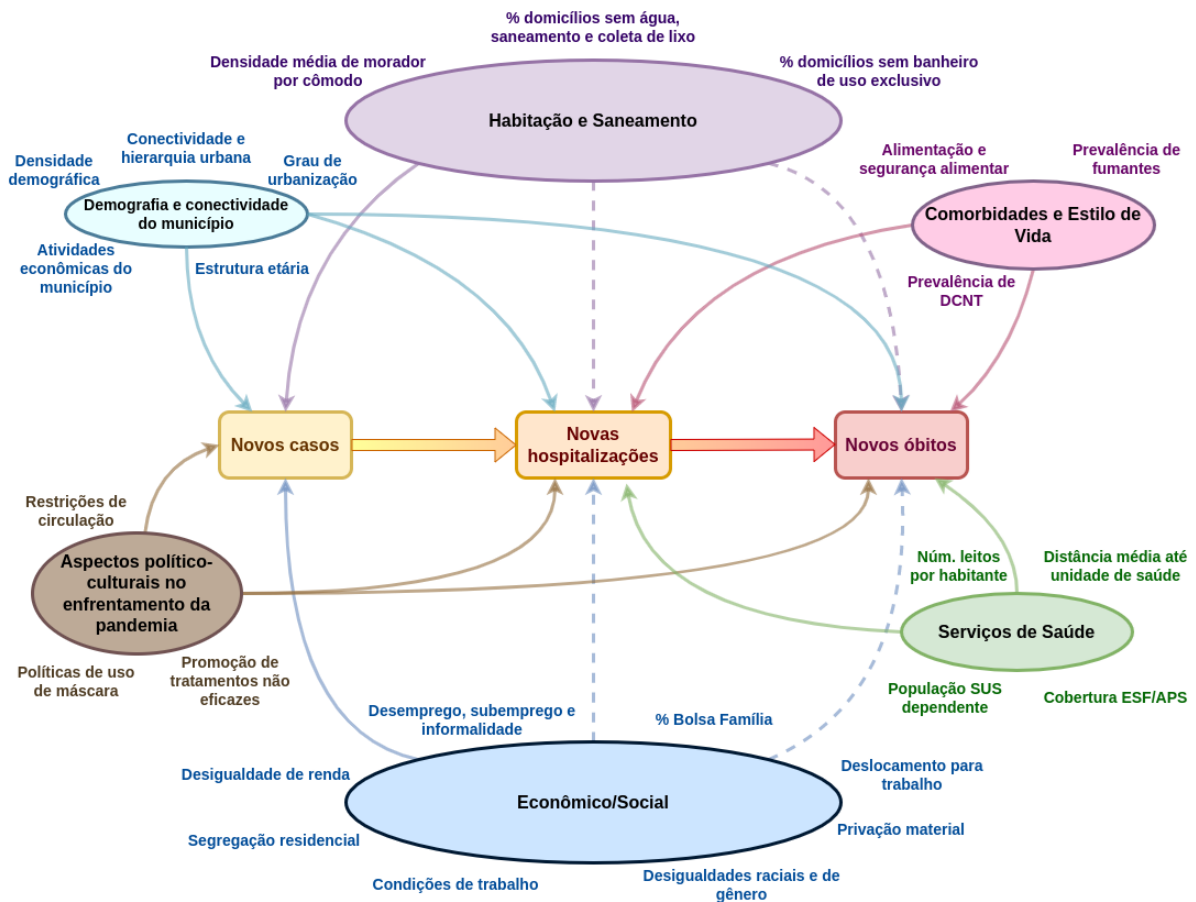
Todos os dados utilizados neste estudo foram obtidos de forma aberta e irrestrita, sem necessidade de requerimento. O projeto de dissertação foi enviado ao Comitê de Ética em Pesquisa da Escola Nacional de Saúde Pública Sergio Arouca CEP-ENSP na data 15/06/2021, e recebeu parecer de dispensa ética N° 06/2021.

6 RESULTADOS

6.1 MODELO TEÓRICO

O modelo teórico construído para fundamentação das análises se encontra na Figura 2. Antes de tudo, reconhece-se a complexidade com que as relações de determinação da saúde se dão na sociedade e especialmente os diversos e inter-relacionados fatores envolvidos em novas infecções pela Covid-19, notificação e testagem, e evolução do caso para hospitalização e óbito. Na tentativa de melhor entender certas relações desse complexo processo, dividiu-se determinados fatores em dimensões – embora fatores de diferentes dimensões também se relacionem de forma particular: demografia e conectividade do município, habitação e saneamento, econômico/social, comorbidades e estilo de vida, serviços de saúde e político/cultural. A partir do modelo obtido, buscou-se a inclusão de variáveis que representassem com mais parcimônia o processo descrito através das dimensões descritas.

Figura 2: Modelo teórico ecológico dos processos e seus fatores determinantes de novos casos, hospitalizações e óbitos por Covid-19.



DCNT: Doenças crônicas não transmissíveis.

ESF/APS: Estratégia Saúde da Família/Atenção Primária à Saúde.

Fatores que caracterizam o município – como sua participação na economia local e regional, sua conectividade e a demografia de sua população – estão contempladas na primeira dimensão. Hipotetiza-se que a influência regional que cada município exerce e seu grau de conexão dentro da rede de municípios, que determina o transporte intermunicipal e o fluxo de pessoas, tenha influência sobre o espalhamento da doença e a geração de novos casos, principalmente nos primeiros momentos da epidemia. Buscou-se representar tais fatores, assim como a densidade, através da variável hierarquia urbana no modelo. Características da população, por sua vez, como a estrutura etária, podem causar variações entre a parcela de casos infectados que evoluem para formas mais graves entre os municípios, dada a primária relação entre idade e agravamento da doença (RANZANI et al., 2021; WOOLF; CHAPMAN; LEE, 2021). A inclusão da variável proporção de idosos no modelo teve como objetivo lidar com

essas diferenças na estrutura etária entre os municípios.

A dimensão de habitação e saneamento buscou envolver, acima de tudo, o acesso a direitos básicos para a população, e cuja falta de oferta resultaria em maior vulnerabilidade social. Tais fatores têm historicamente se relacionado em todas as etapas do processo de evolução da doença – como infecção, agravamento e óbito (FARMER, 1996; CARMO; GUIZARDI, 2018; GAYNOR; WILSON, 2020). No modelo, as relações descritas dentro dessa dimensão estão representadas pelo índice de vulnerabilidade social proposto pelo IPEA (2015).

Fortemente relacionada a essa última, a dimensão econômico/social abrange os fatores sociais e do trabalho, englobando questões como escolaridade, condições de trabalho, desemprego, e principalmente as desigualdades tangentes a esses fatores (QUINN; KUMAR, 2014; MAESTRIPIERI, 2021; SOUZA; SOUZA; MERCES, 2021). O índice GeoSES, incluso no modelo, se propõe a sumarizar para um único valor os contextos socioeconômicos dos municípios a partir de fatores descritos por essa dimensão, como renda, segregação, educação, entre outros (BARROZO et al., 2020).

Como uma manifestação específica envolvida pela dimensão econômico/social, buscase analisar a participação que o trabalho em frigoríficos exerce sobre a distribuição da Covid-19 nos municípios. Hipotetiza-se que a conjunção de fatores envolvendo a prática dessa atividade, como a precariedade de suas condições trabalhistas, habitação e transporte, o ambiente favorável à propagação da doença, e a invisibilização dos trabalhadores que exercem essas funções, tenha sido determinante para maior risco de infecção e agravamento da doença entre esse grupo ocupacional (DE CAMPOS SILVA, 2020; FRENCH NATIONAL ACADEMY OF MEDICINE, 2020; PINA, 2020; GRANADA et al., 2021; MATTA et al., 2021).

Pode-se dizer que o estilo de vida e as comorbidades presentes na população sejam resultado das outras dimensões citadas, uma vez que muitas das escolhas envolvidas no “estilo de vida” da população não são propriamente escolhas, mas imposições e determinações (BARATA, 2009). Optou-se por manter tal dimensão no modelo pelo reconhecimento de sua relação “proximal” com os desfechos de Covid-19 desde o início da pandemia (REZENDE et al., 2020; PERES et al., 2021). São, no entanto, fatores de difícil operacionalização a nível ecológico, e que podem ser fortemente explicados por combinações de fatores das dimensões anteriores, como a maior prevalência de comorbidades entre municípios de menor hierarquia urbana (CROSBY et al., 2012; PAUL et al., 2020) e contexto socioeconômico (CARVALHO; PIRES; XAVIER, 2020; KHALATBARI-SOLTANI et al., 2020).

É reconhecida uma importante e também complexa relação entre a disponibilidade dos serviços de saúde nos municípios e os desfechos da doença, no que se trata principalmente da

relação entre infecções e hospitalizações, e entre hospitalizações e óbitos. Vê-se que essa é uma questão de preocupação sobretudo nos municípios menores, rurais e periféricos (COSTA; COTA; FERREIRA, 2020; RIBEIRO et al., 2020; ALBUQUERQUE; RIBEIRO, 2021; GAMLIN et al., 2021), que possuem, no geral menor concentração de leitos e recursos para lidar com alto número de hospitalizações simultâneas. Por fim, cita-se o contexto político/cultural dos municípios em relação às medidas de enfrentamento à pandemia. Já é reconhecido que fatores de caráter político, como a implementação de medidas de restrição de circulação, incentivo ao uso de máscaras, e promoção de tratamentos não eficazes contra a Covid-19 são aspectos relevantes no que condiz ao controle da epidemia no município (FERIGATO et al., 2020; HENRIQUES; VASCONCELOS, 2020; GAMLIN et al., 2021). Não incluiu-se, no entanto, uma variável referente à essa dimensão na modelagem, e tais aspectos devem ser considerados na interpretação e discussão dos resultados.

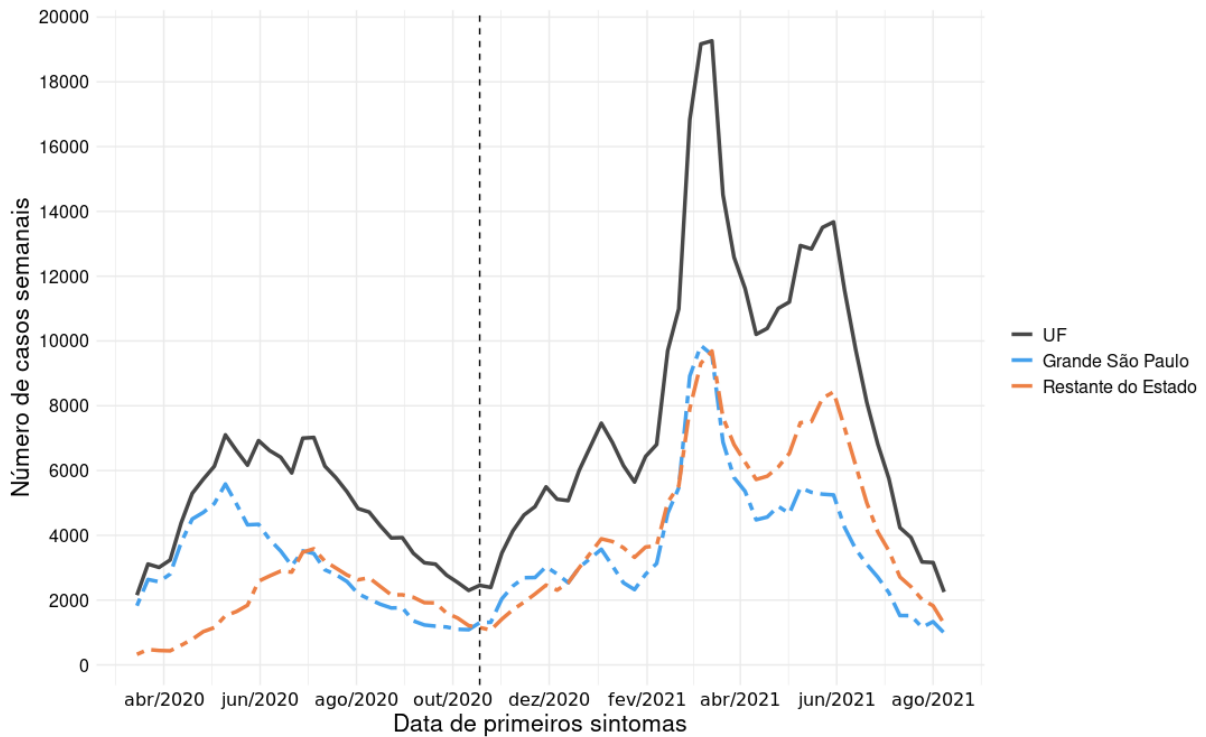
6.2 ANÁLISE EXPLORATÓRIA

6.2.1 SRAG-COVID em São Paulo

Entre março de 2020 e agosto de 2021, registrou-se 509.855 casos de SRAG com classificação final de Covid-19 e UF de residência em São Paulo, e destes, 147.070 evoluíram para óbito (28,85%).

Tem-se o detalhamento da distribuição temporal desses casos no estado através da Figura 3, onde estão expressas as séries de casos semanais no estado como um todo, e divididas entre Grande São Paulo e o restante dos DRS. No início do período, observa-se um constante crescimento no número de casos semanais até julho de 2020, quando se inicia um breve período de queda. Nesse primeiro período, nota-se que os casos predominaram na Grande São Paulo, e após o mês de maio os casos semanais passaram a cair nessa região e a subir nos DRS restantes, sugerindo um processo de interiorização da doença. Todavia, após o mês de outubro de 2020, os casos passam a crescer novamente em ambas as divisões, para o que se configurou como um pico drasticamente maior em março de 2021 (foram 74.221 e 20.907 óbitos em tal mês). Um perfil de queda só foi observado novamente a partir de maio de 2021, se mantendo até o fim do período de estudo.

Figura 3: Casos de SRAG-COVID por semana de primeiros sintomas, entre março de 2020 e agosto de 2021 no estado (UF) e divisão entre Grande São Paulo e restante do estado. Linha pontilhada vertical: divisão do período entre as duas principais curvas de casos.



Fonte dos dados: SIVEP-Gripe.

Para a descrição de alguns resultados, ao invés de realizar recortes anuais, optou-se pela divisão do período de estudo entre essas duas “curvas” perceptíveis e marcadas pela linha pontilhada na Figura 3: a primeira curva, da SE 12 (15/03) até a SE 42 (11/10) de 2020, totalizando 31 semanas; e a segunda curva, da SE 43 (18/10) de 2020 até a SE 32 (08/08) de 2021, totalizando 42 semanas. A Tabela 1 mostra a diferença de incidência e mortalidade nessas duas curvas.

Tabela 1: Número de casos e óbitos de SRAG-COVID em dois períodos (curvas) no estado de São Paulo, março de 2020 a agosto de 2021. Incidência e Mortalidade calculadas por 100.000 habitantes.

Curva	Casos	Óbitos	População*	Incidência SRAG-COVID	Mortalidade SRAG-COVID
Primeira (SE 12/2020 – 42/2020)	149106	40416	44.892.912	332,1371	90,02757
Segunda (SE 43/2020 – 32/2021)	352177	104253		784,4824	232,22597

Fonte dos dados: SIVEP-Gripe.

*: População estimada para 2020. Fonte: IBGE (2020).

SE: Semana epidemiológica.

Pode-se ter uma breve compreensão das regiões mais afetadas ao verificar os números agregados por DRS, expressos na Tabela 2. Na primeira curva, vê-se que os DRS que apresentaram maior incidência foram a Grande São Paulo (421,05 casos por 100.000 hab.) e a Baixada Santista (362,55 casos por 100.000 hab.), junto de São José do Rio Preto (430,95 casos por 100.000 hab.), no interior. Esses três também apresentaram maior mortalidade. Na segunda curva, no entanto, as maiores taxas foram todas entre as regionais do interior: além de São José do Rio Preto (1.283,52 casos por 100.000 hab.), Araçatuba (1.028,90 casos por 100.000 hab.), Barretos (1.008,89 casos por 100.000 hab.), Presidente Prudente (973,64 casos por 100.000 hab.) e Marília (958,04 casos por 100.000 hab.) apresentaram altas taxas de incidência, enquanto a Grande São Paulo (753,37 casos por 100.000 hab.) e a Baixada Santista (492,08 casos por 100.000 hab.) tiveram as 5^a e 1^a menores taxas de incidência em tal recorte, respectivamente.

Tabela 2: Casos e Óbitos por SRAG-COVID nas primeira e segunda curvas agregados por DRS, estado de São Paulo, março de 2020 a agosto de 2021. Incidência e Mortalidade expressas por 100.000 habitantes.

Primeira Curva (SE 12/2020 – 42/2020)					
DRS	População*	Casos	Incidência	Óbitos	Mortalidade
Grande São Paulo	21.252.384	89.483	421,05	23.867	112,30
Araçatuba	766.837	1.836	239,43	473	61,68
Araraquara	996.225	1.350	135,51	334	33,53
Baixada Santista	1.845.822	6.692	362,55	2.252	122,01
Barretos	425.915	1.311	307,81	390	91,57
Bauru	1.749.777	3.431	196,08	753	43,03
Campinas	4.599.489	12.710	276,34	3.639	79,12
Franca	699.771	1.178	168,34	445	63,59
Marília	1.112.483	1.408	126,56	322	28,94
Piracicaba	1.548.612	4.163	268,82	1.182	76,33
Presidente Prudente	754.388	1.824	241,79	379	50,24
Registro	279.699	588	210,23	206	73,65
Ribeirão Preto	1.487.601	4.909	329,99	1.441	96,87
São João da Boa Vista	812.187	1.440	177,30	408	50,23
São José do Rio Preto	1.576.295	6.793	430,95	1.739	110,32
Sorocaba	2.479.246	5.000	201,67	1.233	49,73
Taubaté	2.506.181	4.990	199,11	1.353	53,99
Segunda Curva (SE 43/2020 – 32/2021)					
DRS	População*	Casos	Incidência	Óbitos	Mortalidade
Grande São Paulo	2.1252.384	89.483	753,37	23.867	206,82
Araçatuba	766.837	1.836	1.028,90	473	345,71
Araraquara	996.225	1.350	772,82	334	228,86
Baixada Santista	1.845.822	6.692	492,08	2.252	236,81
Barretos	425.915	1.311	1.008,89	390	309,45
Bauru	1.749.777	3.431	894,97	753	260,32

Segunda Curva (SE 43/2020 – 32/2021)

DRS	População*	Casos	Incidência	Óbitos	Mortalidade
Campinas	4.599.489	12.710	779,83	3.639	220,68
Franca	699.771	1.178	608,34	445	220,21
Marília	1.112.483	1.408	958,04	322	325,13
Piracicaba	1.548.612	4.163	702,56	1.182	233,11
Presidente Prudente	754.388	1.824	973,64	379	276,65
Registro	279.699	588	755,10	206	238,83
Ribeirão Preto	1.487.601	4.909	769,09	1.441	236,42
São João da Boa Vista	812.187	1.440	780,12	408	290,70
São José do Rio Preto	1.576.295	6.793	1.283,52	1.739	368,97
Sorocaba	2.479.246	5.000	863,33	1.233	284,40
Taubaté	2.506.181	4.990	674,57	1.353	187,74

Fonte dos dados: SIVEP-Gripe.

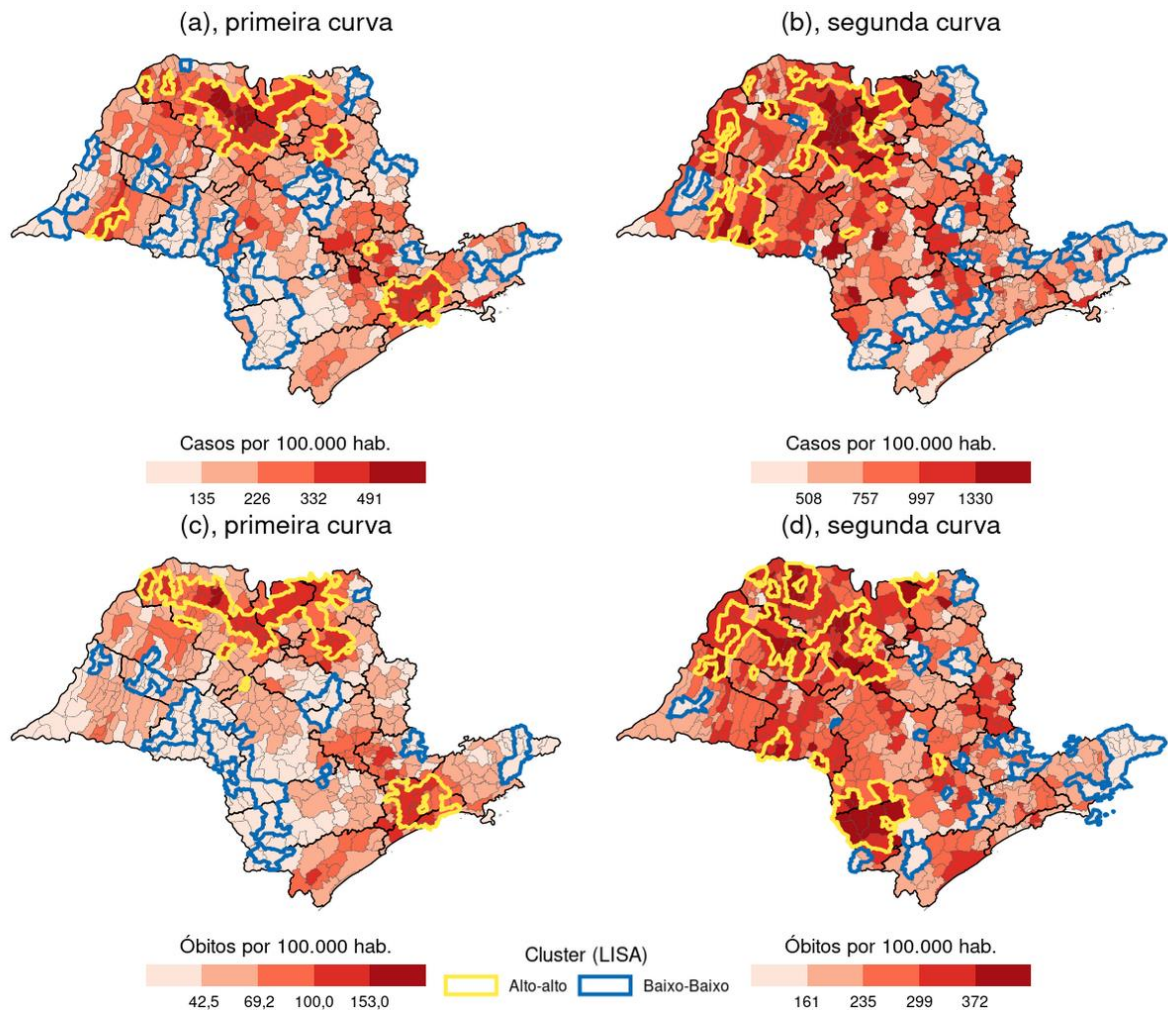
*: População estimada para 2020. Fonte: IBGE (2020).

DRS: Departamento Regional de Saúde

SE: Semana epidemiológica.

Padrões espaciais das taxas de incidência e mortalidade podem ser melhor compreendidos através dos mapas coropléticos da Figura 4. Nela, consta a distribuição espacial das taxas suavizadas em cada uma das duas curvas, bem como os aglomerados significativos encontrados através dos indicadores locais de associação espacial (LISA). Na primeira nota-se o protagonismo de duas regiões, com altas taxas: uma envolvendo os DRS da Grande São Paulo e Baixada Santista; e outra no Noroeste e Nordeste paulista, principalmente no DRS de São José do Rio Preto. Outros centros ou capitais regionais também apresentaram destaque, como Ribeirão Preto e Presidente Prudente. Alguns DRS apresentaram formação de aglomerados “Baixo-baixo”, destacando-se por taxas abaixo da média do estado, como Bauru, Marília, Araraquara e São João da Boa Vista.

Figura 4: Distribuição espacial por município de casos (a, b) e óbitos (c, d) por SRAG-COVID por 100.000 habitantes entre dois períodos (curvas), de março de 2020 a agosto de 2021, suavizados espacialmente, junto aos aglomerados encontrados pelos indicadores locais de associação espacial (LISA), estado de São Paulo, Brasil. Primeira curva: SE 12/2020 – 42/2020; Segunda curva: SE 43/2020 – 32/2021.



Fonte dos dados: SIVEP-Gripe.

No entanto, padrões preocupantemente diferentes são observados na segunda curva. As maiores taxas de incidência e mortalidade se distribuíram de forma mais homogênea entre os DRS do interior do estado, e regionais que no ano anterior apresentaram baixas taxas se destacaram negativamente em tal período. O DRS São José do Rio Preto seguiu com os maiores números de incidência e mortalidade; Barretos, Ribeirão Preto e Presidente Prudente apresentaram situação ainda pior na segunda curva e Araçatuba, Araraquara, Marília e Bauru

que antes concentraram aglomerados “Baixo-baixo” passaram a apresentar situação oposta. Destacam-se também as regionais que não apresentaram altas taxas de incidência mas tiveram altas taxas de mortalidade, como é o caso do DRS de Sorocaba, que mostrou aglomerados “Baixo-baixo” para incidência e aglomerados “Alto-alto” para mortalidade na segunda curva. Em nenhum recorte temporal houve aglomerados “Alto-baixo” ou “Baixo-alto” significativos.

6.2.2 Distribuição e correlação entre as covariáveis

As variáveis GeoSES e IVS foram mantidas em sua forma original de obtenção, a nível de município. A hierarquia urbana, obtida através da combinação das classificações das regiões de influência dos territórios e da caracterização urbano/rural do IBGE, resultou na classificação de 298 municípios como rurais, 198 como urbanos, 104 capitais regionais e 45 metrópoles. Quanto aos dados da RAIS, foram obtidos 19.207.029 registros de vínculos empregatícios em 2020 no estado de São Paulo, sendo que 56.949 (0,2965%) desses eram relacionados à atividade frigorífica, conforme exposto na Tabela 5. Ressalta-se que não há nenhum identificador pessoal na base, portanto há a possibilidade de que mais de um registro se refira ao mesmo indivíduo. O DRS que mais apresentou registros referentes a atividades frigoríficas no estado foi São José do Rio Preto, onde aproximadamente 22 registros a cada 1.000 na regional eram desse ramo. No apêndice A (Figura S2) é possível verificar a distribuição da razão de trabalhadores de frigorífico nos municípios a cada 1.000 registrados na RAIS. Ao tratar a variável em sua forma categórica, tem-se que 523 municípios (81,09%) não possuem atividade frigorífica (“Não”) e 122 (18,91%) possuem (“Sim”). A distribuição desses registros entre as subclasses CNAE 2.0 pode também ser vista no apêndice A (Quadro S1).

Tabela 3: Total de vínculos encontrados na RAIS 2020, número de vínculos relacionados à atividade frigorífica e sua razão, total e por DRS, estado de São Paulo, 2020.

Região (UF/DRS)	Total Registros		Registros Atividade Frigorífica	Razão (x1000)
	RAIS			
SP (Total)	19.207.029		56.949	2,965
São José do Rio Preto	589.006		13.030	22,1220
Presidente Prudente	216.459		4.752	21,9533
Bauru	662.959		11.299	17,0433
Franca	236.416		2.408	10,1854
Sorocaba	881.437		7.281	8,2604
São João da Boa Vista	298.074		1.802	6,0455
Marília	386.590		1.829	4,7311
Piracicaba	616.406		2.550	4,1369
Campinas	2.007.517		7.342	3,6573
Ribeirão Preto	628.644		1.433	2,2795
Araçatuba	249.790		551	2,2059
Barretos	186.009		181	0,9731
Araraquara	404.082		288	0,7127
Registro	62.869		29	0,4613
Grande São Paulo	10.459.619		2.042	0,1952
Taubaté	807.325		132	0,1635
Baixada Santista	513.827		0	0

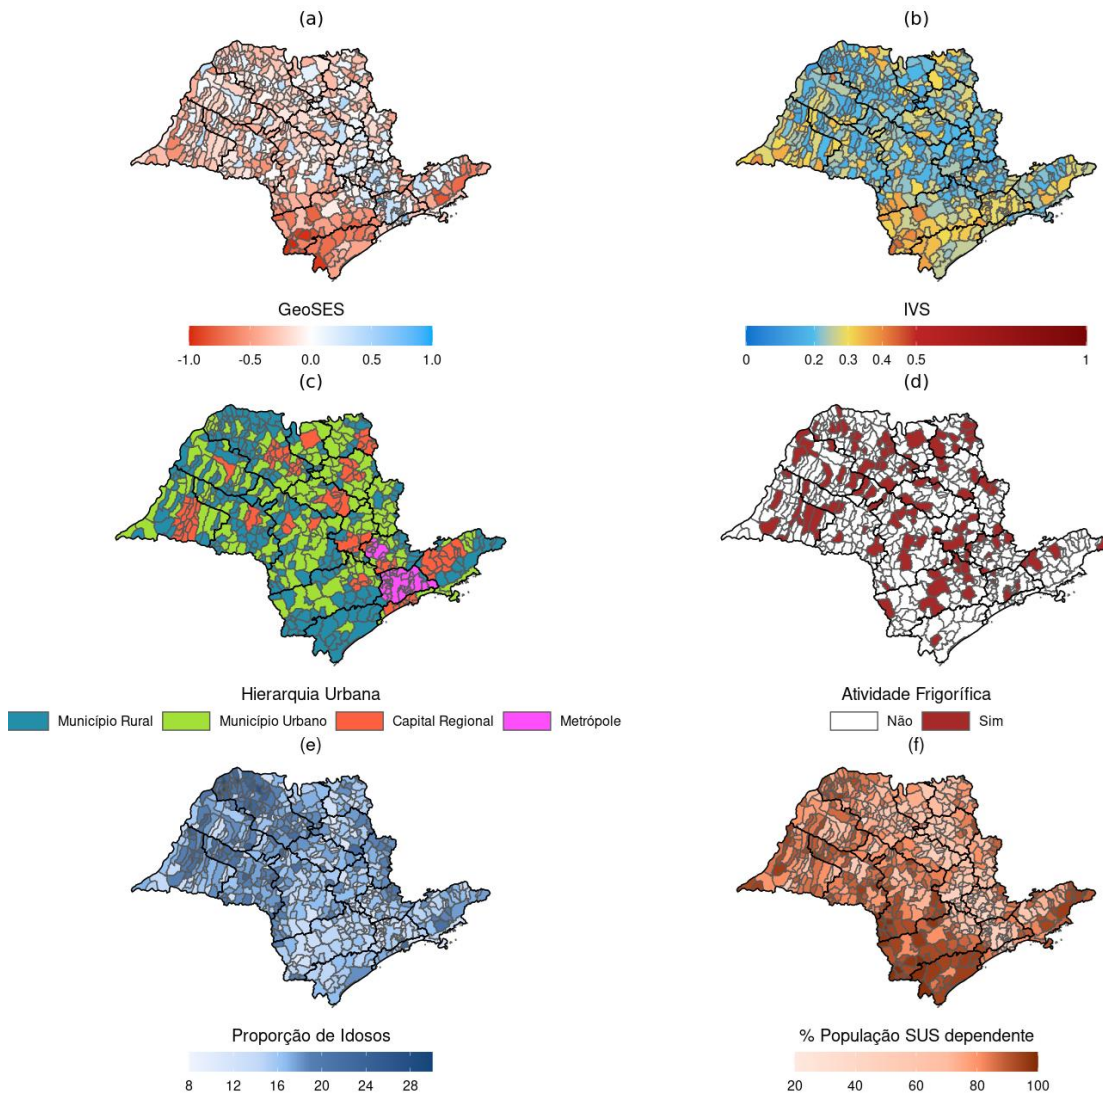
DRS: Departamento Regional de Saúde.

RAIS: Relação Anual de Informações Sociais.

Fonte dos dados: Programa de Disseminação das Estatísticas do Trabalho (PDET).

A distribuição espacial das covariáveis do estudo se encontra na Figura 5. Ao olhar para os índices GeoSES e IVS (5a e 5b, respectivamente), destaca-se as periferias do estado e o Sul paulista, envolvendo os DRS de Sorocaba e Registro, que possuem baixos índices socioeconômicos e média/alta vulnerabilidade social ($IVS > 0,3$ (IPEA, 2015)). Embora os dois índices sejam concordantes em diversas partes do estado, ao voltar-se para os DRS de Grande São Paulo e Baixada Santista vê-se que os municípios dessas regionais possuem altos índices socioeconômicos, segundo o GeoSES, mas também média/alta vulnerabilidade, segundo o IVS.

Figura 5: Distribuição espacial das variáveis GeoSES (a), IVS (b), Hierarquia Urbana (c), Atividade Frigorífica em 2020 (d), Proporção de Idosos em 2020 (e) e % População SUS Dependente em 2020 (f), no estado de São Paulo.



Fonte dos dados: Barrozo *et al.* (2020); IPEA (2015); IBGE(2017, 2018b); Programa de Disseminação das Estatísticas do Trabalho (PDET); SEADE; Secretaria de Estado da Saúde (SES/SP).

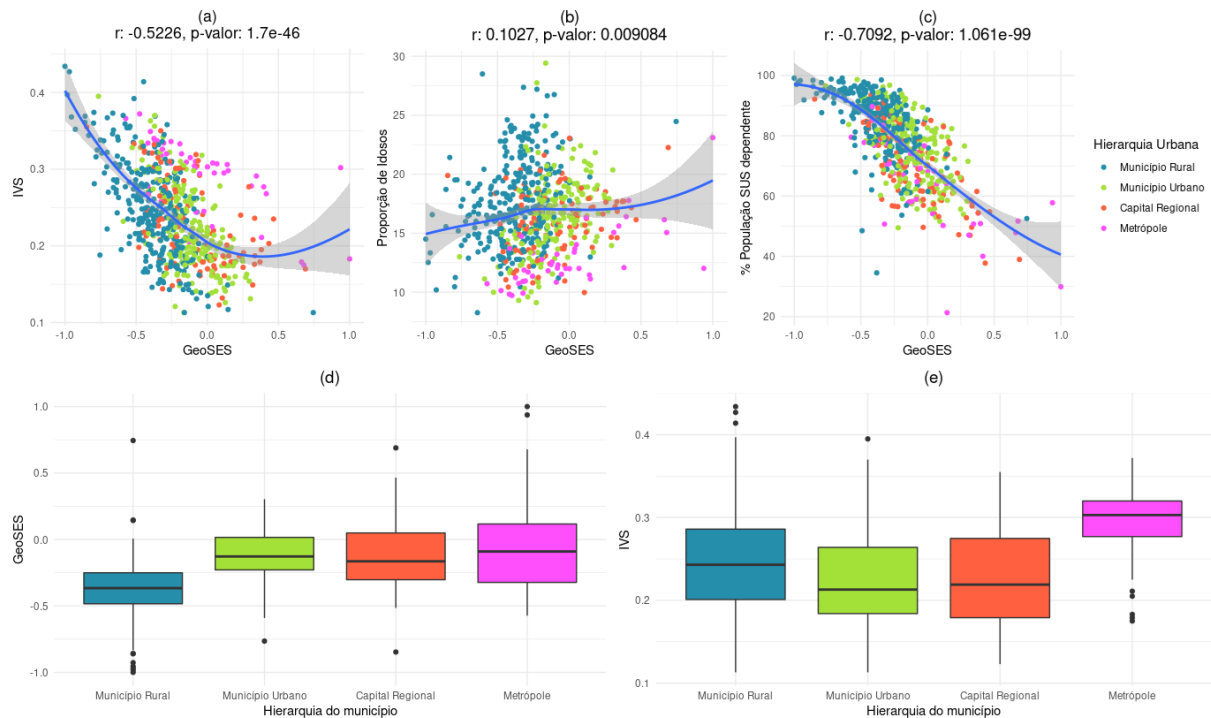
Ao tratar da hierarquia urbana (5c) dos municípios, vê-se a concentração de metrópoles nas regiões da Grande São Paulo e Campinas, e um espalhamento das capitais regionais entre os DRS do estado – com exceção apenas de São João da Boa Vista e Registro. Esse último destaca-se também por possuir quase todos seus municípios classificados como rurais.

A variável que menos apresenta padrões espaciais nítidos é a que representa a atividade frigorífica nos municípios (5d); há ao menos um município com atividade frigorífica em todos os DRS do estado, com exceção da Baixada Santista.

Para a proporção de idosos (5e), observa-se um predomínio de municípios com maior percentual de população idosa entre os DRS do interior do estado, como Presidente Prudente, Marília e São José do Rio Preto. A Grande São Paulo e os DRS do Sul do estado (Sorocaba e Registro) concentraram os municípios com menor proporção de idosos. O percentual de população SUS dependente (5f) apresentou distribuição espacial similar à do índice GeoSES, onde aparenta-se que as regiões de pior índice socioeconômico tendem a apresentar maior parcela da população dependente do SUS.

Explorou-se as correlações entre algumas variáveis do estudo, conforme disposto na Figura 6. Há uma relação linear inversa considerável entre os índices GeoSES e IVS (r estimado = -0,5226), com um rompimento na tendência linear para os municípios de alto índice socioeconômico que possuem também alta vulnerabilidade – em sua maior parte, as metrópoles. Visando evitar a multicolinearidade em etapas futuras na análise, optou-se por trabalhar alternativamente com o IVS na forma categorizada, dividindo os municípios entre aqueles com baixa vulnerabilidade ($IVS < 0,3$) e com média ou alta vulnerabilidade ($IVS \geq 0,3$). A distribuição espacial do índice categorizado se encontra no apêndice A (Figura S1). Encontrou-se uma baixa correlação linear direta entre o GeoSES e a proporção de idosos (r estimado = 0,1027) e uma alta e inversa entre o GeoSES e o percentual da população SUS dependente (r estimado = -0,7092).

Figura 6: Diagramas de dispersão com linha auxiliar loess da variável GeoSES com as variáveis IVS (a), proporção de idosos (b) e Porcentagem da população SUS dependente (c). Ao topo, o coeficiente de correlação linear (r) estimado. Boxplots dos índices GeoSES (d) e IVS (e) entre as categorias de Hierarquia Urbana.



Fonte dos dados: Barrozo *et al.* (2020); IPEA (2015); IBGE(2017, 2018b); SEADE; Secretaria de Estado da Saúde (SES/SP).

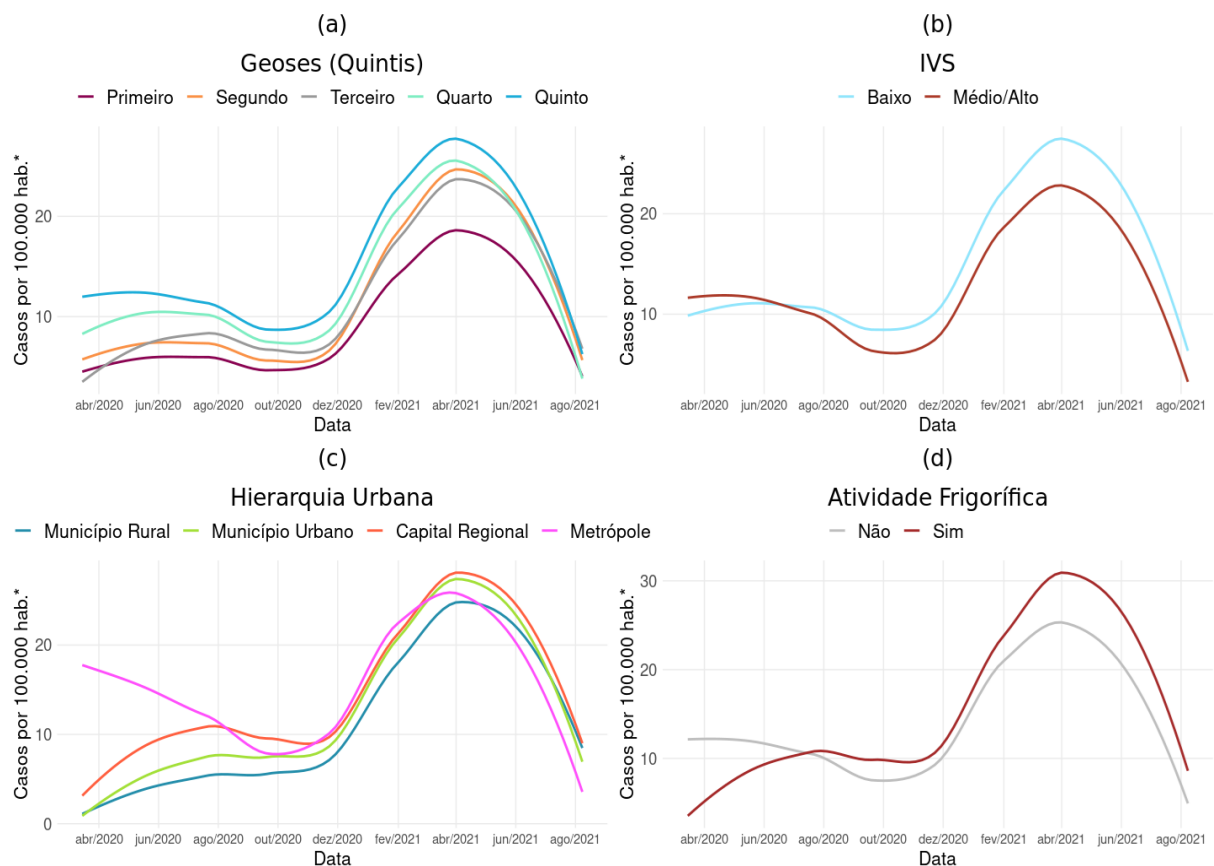
Na parte inferior da Figura (6d e 6e) analisa-se as distribuições dos índices entre as categorias de hierarquia urbana. Vê-se que as maiores categorias de hierarquia tendem a apresentar melhores índices socioeconômicos, embora com maior variabilidade; e que há um padrão interessante ao tratar-se de vulnerabilidade: os municípios rurais e as metrópoles são as categorias que apresentam, em média, maior vulnerabilidade social.

6.2.3 Incidência e mortalidade de SRAG-COVID entre as covariáveis

Pode-se ter uma breve noção da relação entre cada covariável e o desfecho ao longo do tempo ao investigar as variações das taxas entre as categorias dessas covariáveis. O índice contínuo GeoSES foi categorizado em quintis para que isso fosse possível: primeiro quintil ($[-1; -0.42]$); segundo quintil ($[-0.42; -0.3]$); terceiro quintil ($[-0.3; -0.19]$); quarto quintil ($[-0.19; -0.03]$); e quinto quintil ($[-0.03; 1]$). O IVS foi mantido na sua categorização entre baixo e

médio/alto. Assim, as séries semanais suavizadas de incidência de SRAG-COVID entre os níveis das covariáveis estão dispostas na Figura 7. Apresentou-se resultados relacionados a incidência, mas padrões similares foram encontrados ao analisar a mortalidade. Tais resultados podem ser encontrados no apêndice A (Figura S3).

Figura 7: Casos de SRAG-COVID semanais por 100.000 habitantes suavizados pelo método loess entre março de 2020 e agosto de 2021 por quintis de GeoSES (a), categoria de IVS (b), hierarquia urbana (c) e atividade frigorífica (d).



*: Taxa suavizada temporalmente pelo método loess.

Fonte dos dados: SIVEP-Gripe, Barrozo *et al.* (2020); IPEA (2015); IBGE(2017, 2018b); Programa de Disseminação das Estatísticas do Trabalho (PDET).

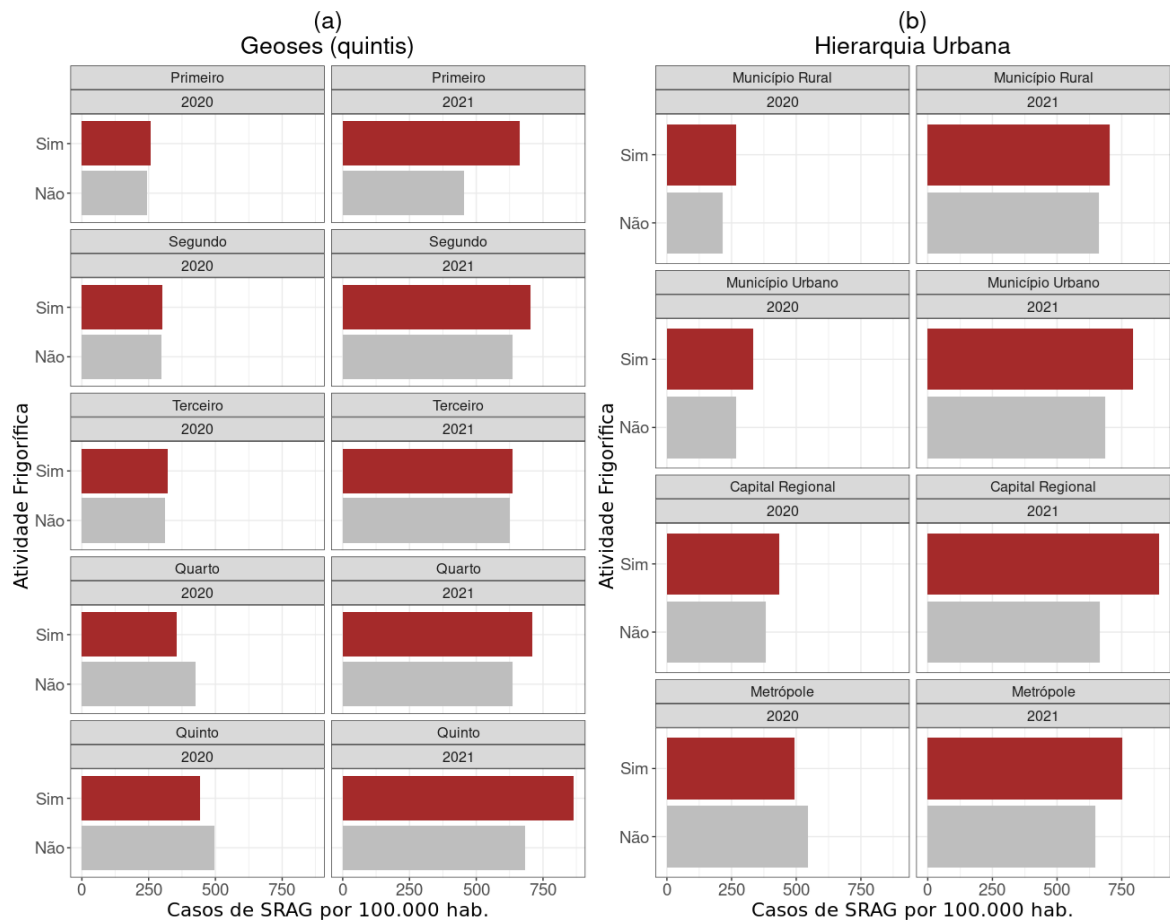
Entre os quintis do GeoSES, observa-se um gradiente em que os municípios com maiores valores de índice socioeconômico tiveram as maiores incidências semanais durante todo o período e os quintis mais baixos – em especial o primeiro – as menores. Nota-se que em 2021 o segundo quintil teve um aumento considerável e se juntou aos outros quintis com taxas mais altas. Um padrão também inesperado se observa para os níveis de IVS: os municípios com baixa vulnerabilidade apresentaram maior incidência no período, com exceção para um breve

recorte antes de junho de 2020. Nesse primeiro período, a concentração dos casos nas metrópoles – que têm alta vulnerabilidade – podem ter elevado a incidência para esta categoria.

Um padrão interessante se nota ao analisar o desfecho entre as categorias de hierarquia urbana. Vê-se que as metrópoles apresentaram maior incidência, com folga para as outras categorias, durante os primeiros meses da epidemia. O padrão se manteve até agosto de 2020, quando a incidência semanal nas metrópoles foi ultrapassada pela das capitais regionais, que vinha crescendo junto a dos municípios rurais e urbanos. A partir do final de 2020 há um crescimento nas taxas em todas as categorias até abril de 2021, quando, lideradas pelas metrópoles, as incidências semanais passam a cair. Um fenômeno de inversão também é observado entre as séries por categorias de atividade frigorífica. A incidência semanal passou a ser maior entre os municípios com atividade frigorífica a partir de agosto de 2020, e esse padrão se manteve até o fim do período.

Para melhor compreender como essas taxas de incidência variaram nos municípios com e sem atividade frigorífica, verificou-se a distribuição dessas taxas em cada ano dentre os quintis de GeoSES e as categorias de hierarquia urbana, nos anos de 2020 e 2021. Na Figura 8 pode-se perceber que em 2020 a incidência nos municípios com atividade frigorífica foi mais alta entre os quintis mais baixos de GeoSES apenas. Nos quarto e quinto quintis, os municípios sem frigoríficos tiveram maiores taxas. Um padrão semelhante foi observado entre as categorias de hierarquia urbana, onde em 2020 a incidência foi maior para os municípios com atividade frigorífica dentre os municípios rurais, urbanos e capitais regionais, observando-se o oposto para as metrópoles. No entanto, o ano de 2021 revela outro padrão, onde os municípios com atividade frigorífica tiveram maior incidência em todas as categorias de GeoSES ou hierarquia urbana.

Figura 8: Casos de SRAG-COVID por 100.000 habitantes em São Paulo em cada ano, de março de 2020 a agosto de 2021, por categoria de atividade frigorífica, entre os quintis de GeoSES (a) e categorias de hierarquia urbana (b).



Fonte dos dados: SIVEP-Gripe, Barrozo *et al.* (2020); IPEA (2015); IBGE(2017, 2018b); Programa de Disseminação das Estatísticas do Trabalho (PDET).

6.3 MODELAGEM ESTATÍSTICA

6.3.1 Estrutura dos modelos estatísticos

Tomando como base o modelo apenas com componentes espacial e temporal não estruturados, inseriu-se diferentes combinações de efeitos aleatórios a fim de identificar uma estrutura para o modelo que melhor capturasse a variação existente nos riscos relativos de casos por SRAG-COVID, e que condissesse com o modelo teórico. Ao todo, ajustou-se e registrou-se 73 modelos para o desfecho de casos de SRAG-COVID. Alguns desses modelos estão

explicitados na Tabela 4.

Tabela 4: Exemplos de composições de efeitos aleatórios testadas para a estrutura do modelo estatístico para casos de SRAG-COVID.

# Distribuição	Componente (% da variância explicada)			DIC
	Espacial	Temporal	Interação espaço-tempo	
1 Poisson	IID (32,30%)	IID (67,70%)	-	122.688,80
2 Poisson	Besag (59,80%)	IID (40,20%)	-	122.674,21
3 Poisson	BYM (45,10%)	IID (54,90%)	-	122.667,04
4 Poisson	BYM2 (34,30%)	IID (65,60%)	-	122.666,74
5 Poisson	BYM2 (40,60%)	RW1 (59,40%)	-	122.666,39
6 Poisson	BYM2 (42,80%)	RW1 + IID (57,30%)	-	122.666,46
7 Poisson	BYM2 (56,60%)	RW2 (43,40%)	-	122.673,68
8 Poisson	BYM2 (59,10%)	RW2 + IID (40,90%)	-	122.666,32
9 Binomial Negativa	BYM2 (55,80%)	RW2 + IID (44,30%)	-	66.705,62
10 Binomial Negativa	BYM2 (8,50%)	RW2 (11,50%)	Tipo IV: por DRS (79,90%)	64.181,84
11 Binomial Negativa	BYM2 (11,20%)	RW2 (12,10%)	Tipo IV: por Região de Saúde (76,70%)	63.546,86
12 Poisson	BYM2 (0,60%)	RW2 + IID (4,60%)	Tipo IV: por Município (93,80%)	58.332,47

IID: Componente não estruturado.

BYM: Besag + IID (Modelo Besag-York-Mollié (BESAG; YORK; MOLLIE, 1991)).

BYM2: Besag + IID (BYM) com reparametrização (RIEBLER et al., 2016).

RW1 e RW2: Random Walk de ordens 1 e 2.

DIC: Critério de Informação de Deviance.

A inclusão de efeitos espacialmente estruturados no modelo melhorou seu ajuste e aumentou a parcela de variância explicada pelo componente espacial, como esperado. A parametrização com melhor ajuste foi a do modelo BYM2, embora a diferença no DIC para os modelos BYM e CAR puro tenha sido relativamente pouca. Posteriormente no processo de modelagem, verificou-se que o componente espacial não estruturado não contribuía de forma relevante para a captura de variância do desfecho (Apêndice A, Figura S5), e dessa forma optou-se por manter nos modelos seguintes apenas o componente estruturado.

Entre as estruturas temporais, a combinação dos efeitos Random Walk 2 e não estruturado apresentou um ajuste ligeiramente melhor, além de um efeito temporal estruturado mais suavizado (Apêndice A, Figura S5). Verificou-se, no entanto, que de forma similar aos efeitos espaciais, o componente não estruturado não apresentou contribuições para a explicação do desfecho (apenas 0,20% da variância) e assim também foi descartado para as etapas seguintes. É possível também ver na tabela que houve uma redução expressiva – de cerca de 46% – no DIC ao trocar a verossimilhança para Binomial Negativa (modelo 9). As verossimilhanças que tratam de inflação em zero – ZIP e ZINBI – também foram testadas. Apesar da alta concentração de valores zero nos primeiros meses do período de estudo, não houve melhora no ajuste com o modelo ZIP. O modelo ZINBI apresentou valor de DIC semelhante ao da Binomial Negativa, contudo a precisão dos hiperparâmetros foi reduzida. Dessa forma, a verossimilhança Binomial Negativa foi mantida para o restante do processo de modelagem.

A inclusão de um componente de interação espaço-tempo, de qualquer tipo, acarretou em melhorias no DIC. As interações do tipo IV apresentaram melhor ajuste, seguidas das do tipo II e tipo I. A unidade espacial para a interação que apresentou melhores resultados foi, no geral, a Região de Saúde, embora a interação a nível de município tenha apresentado melhor DIC quando utilizou-se novamente a verossimilhança Poisson. Considerou-se, no entanto, que utilizar uma interação espaço-tempo a nível de município resultaria em um modelo propenso a *overfitting*, uma vez que seriam estimados efeitos para cada combinação de município e tempo. Além do mais, julgou-se que utilizar interações a nível de Região de Saúde traria, além de parcimônia, maior sentido teórico, uma vez que os cursos da epidemia variaram regionalmente com o tempo (CASTRO et al., 2021a). Ao mesmo tempo, considerou-se o DRS uma unidade muito abrangente, de forma que as situações da epidemia dentro do mesmo DRS poderiam ser muito diferentes.

Dessa forma, obteve-se um modelo base para iniciar a inclusão das covariáveis:

$$\eta_{it} = \beta_0 + \phi_i + \gamma_t + \delta_{kt} \quad (15),$$

onde ϕ_i é o efeito espacial estruturado para a área i , γ_t é o efeito temporal estruturado no tempo t e δ_{kt} a interação do tipo IV – entre os efeitos espacial e temporal estruturados – na região de saúde k no tempo t . Tem-se que cada um dos 645 i 's pertence a um único grupo k . O mesmo modelo base encontrado para casos de SRAG-COVID foi utilizado também apenas para os óbitos. No entanto, foram encontrados problemas na estimação com a verossimilhança Binomial Negativa, e por isso para esse desfecho foi utilizada a verossimilhança Poisson.

Ao incluir as covariáveis, viu-se que todas elas contribuíram para o ajuste do modelo em termos de DIC, entre os modelos simples. Ao testar a possibilidade de coeficientes variando no tempo, no entanto, apenas a variável GeoSES apresentou intervalos de credibilidade (I. cred.) que não incluíam o valor nulo. Contudo, os valores pontuais estimados não tiveram mudanças relevantes entre os períodos de tempo (Apêndice A, Figura S6), e dessa forma optou-se por tratar todos os efeitos como fixos no tempo. Nos modelos múltiplos, apenas a variável relativa ao IVS não contribuiu, em sua forma contínua ou categorizada, para a redução do DIC quando inserida no modelo com as outras variáveis. Ainda assim, decidiu-se mantê-la no modelo final, ressaltando sua importância considerando o modelo teórico. Dessa forma, obteve-se como modelos finais, tanto para casos quanto para óbitos:

$$\begin{aligned} \eta_{it} = & \beta_0 + \beta_1 \times \text{GeoSES}_i + \beta_2 \times \text{Hierarquia Urbana: Município Urbano}_i \\ & + \beta_3 \times \text{Hierarquia Urbana: Capital Regional}_i \\ & + \beta_4 \times \text{Hierarquia urbana: Metr pole}_i + \beta_5 \times \text{Atividade Frigor fica:Sim}_i \\ & + \beta_6 \times \text{IVS:M dio/Alto}_i + \beta_7 \times \text{Propor o de Idosos}_i + \phi_i + \gamma_t + \delta_{kt} \end{aligned}$$

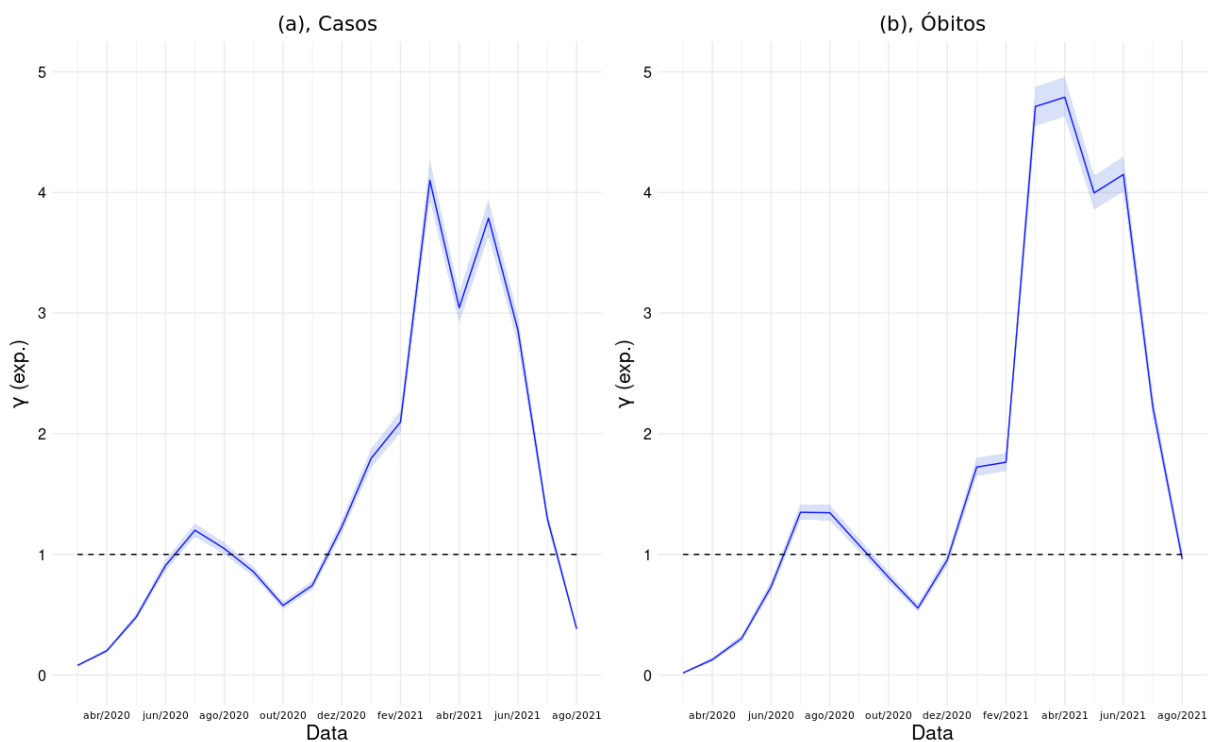
(16),

6.3.2 Resultados dos modelos estat sticos

Os efeitos temporais estruturados (γ) estimados para os modelos de casos e  bitos est o representados na Figura 9. Os efeitos foram exponenciados de forma que podem ser interpretados como risco relativo para cada m s, ap s controle pelas covari veis e condicionando   estrutura espacial. Alguns padr es observados real am o que foi visto na Figura 3, onde nota-se um efeito crescente desde o in cio do per odo e que atinge o primeiro pico em julho de 2020, para os casos de SRAG-COVID. Um per odo decrescente se segue at  outubro para os casos e novembro para os  bitos, quando se configura um novo crescimento com pico estrondosamente maior – onde atingem-se riscos relativos superiores a 4 – em mar o e abril de 2021 para casos e  bitos, respectivamente. Nota-se que os padr es observados para

os casos tendem a se refletir para os óbitos com certo período de atraso – de em média, um mês. O patamar atingido para óbitos, no entanto, teve maior magnitude (RR = 4,79 (I. cred.: 4,62-4,96), em abril de 2021; para casos: RR = 4,10 (I. cred.: 3,93-4,27), em março de 2021).

Figura 9: Efeitos temporais estruturados (γ) estimados, junto ao intervalo de credibilidade de 95%, nos modelos estatísticos para Casos (a) e Óbitos (b) por SRAG-COVID no estado de São Paulo.

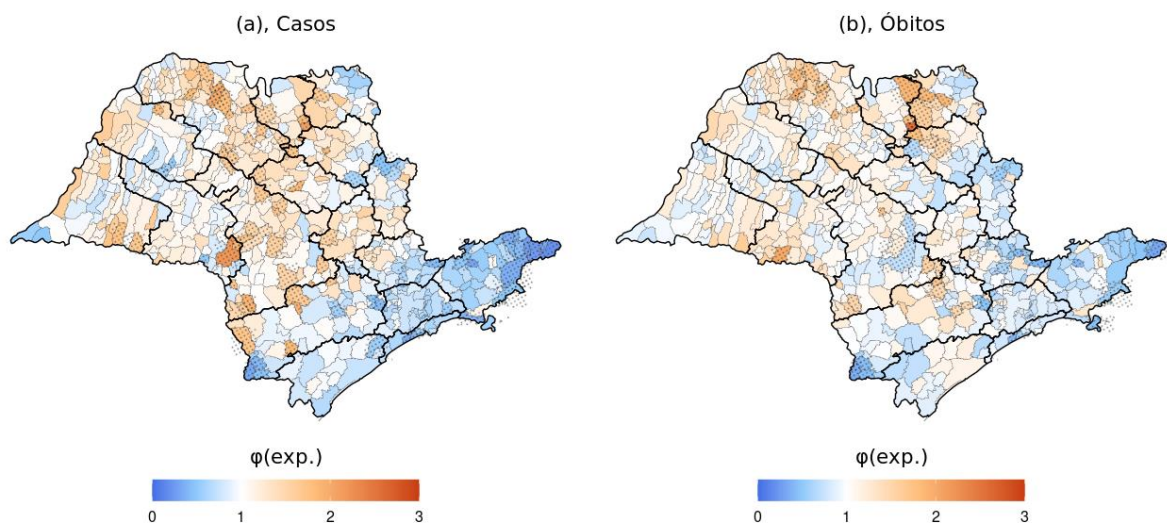


Ainda observando o efeito temporal, destaca-se a forma desproporcional com que os anos de 2020 e 2021 foram afetados pela pandemia. Em 2020, poucos meses foram apontados como “risco”, enquanto todos os meses de 2021 tiveram γ médio exponenciado maior do que 1 e com altíssima magnitude, com exceção do mês agosto. Além disso, também ressalta-se as baixas amplitudes dos intervalos de credibilidade dos efeitos, em que para poucos meses (agosto de 2020 para casos; dezembro de 2020 e agosto de 2021 para óbitos) o valor 1 esteve incluso nesses intervalos. O componente temporal estruturado foi responsável pela explicação de 14,6% da variância no modelo final para casos e 8,9% no modelo para óbitos.

Os efeitos espaciais estruturados (ϕ) exponenciados dos modelos de casos e óbitos se encontram na Figura 10. Uma vez que a maior concentração de casos e óbitos se deu no ano de 2021, observa-se que os padrões encontrados através do efeito espacial se assemelham com os

padrões da distribuição espacial de casos e óbitos em 2021. Assim, os municípios dos DRS do sudeste do estado: Grande São Paulo, Baixada Santista e Taubaté apresentaram baixos valores de ϕ . Nos DRS de Campinas, São João da Boa Vista, Sorocaba e Registro, houve uma heterogeneidade intra-regional entre os valores de ϕ , e nos DRS restantes houve uma maior concentração de municípios classificados como risco. Ressalta-se que esse efeito espacial representa padrões espaciais que, em média, se mantiveram durante o todo período. Destaca-se as regionais do Noroeste e Nordeste paulista: São José do Rio Preto, Barretos, Franca e Ribeirão Preto que apresentaram altos de valores de ϕ para ambos casos e óbitos.

Figura 10: Efeitos espaciais estruturados (ϕ) exponenciados para os modelos estatísticos de casos (a) e óbitos (b) por SRAG-COVID, no estado de São Paulo. Polígonos preenchidos com pontilhado não tiveram o valor 1 contido em seu intervalo de credibilidade para ϕ .

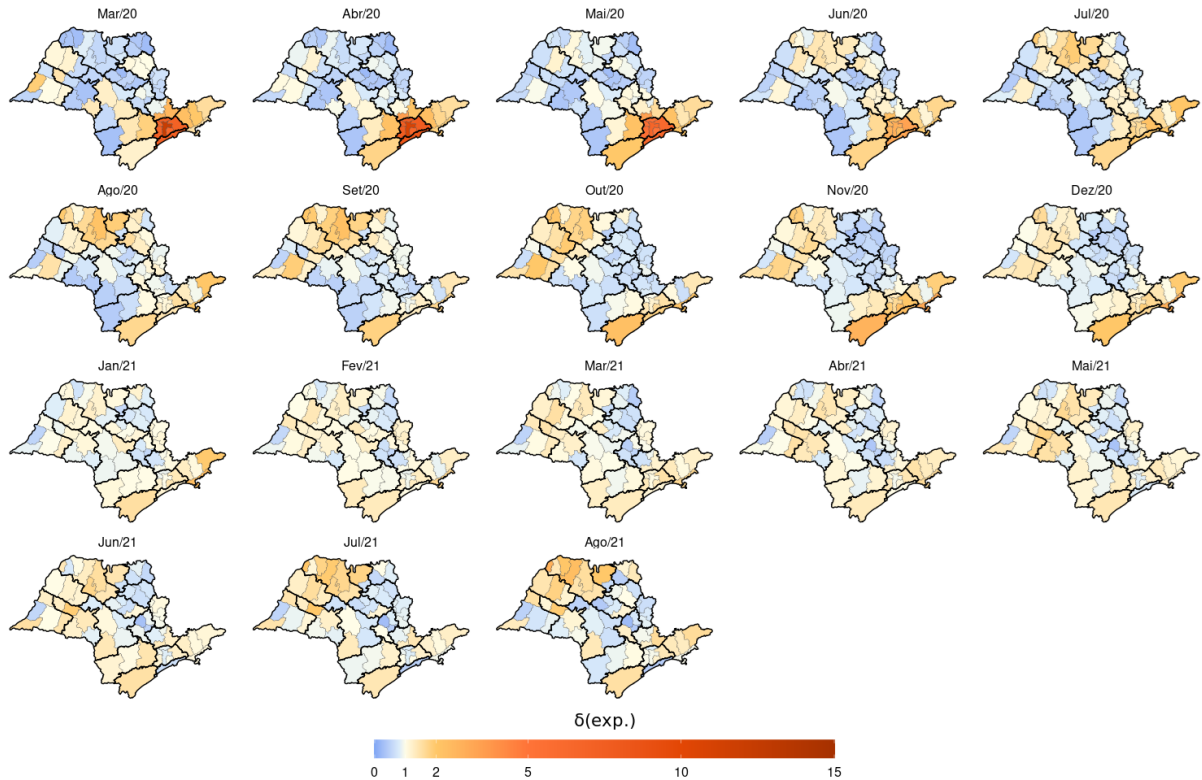


Vê-se também que foram poucos os municípios (89 (13,79%) entre os casos e 56 (8,68%) entre os óbitos) cujos intervalos de credibilidade para o valor de ϕ exponenciado não incluíram o 1. Isso condiz com o fato de que o efeito espacial estruturado contribuiu para a explicação de 23,9% da variância entre os casos e apenas 7,2% para óbitos, reforçando a hipótese da especificidade contextual da epidemia em diferentes regiões e momentos do tempo.

O componente de interação espaço-tempo (δ), por sua vez, foi o principal em termos de explicação da variância nos dois modelos, sendo responsável pela explicação de 61,6% e

83,9% da variância nos modelos de casos e óbitos, respectivamente. Sua distribuição espacial para as 63 regiões de saúde ao longo dos meses está exposta na Figura 11. Nota-se valores altos de δ exponenciado – atingindo patamares da ordem $\delta > 10$ nos primeiros três meses entre as regiões de saúde dos DRS Grande São Paulo e Baixada Santista. Ressalta-se que nesse período inicial, o efeito temporal global, que age sobre o estado como um todo, é baixo. Porém as regionais destacadas já concentravam altos registros de casos e óbitos justamente por incluírem a capital, município de entrada da doença, e seus municípios vizinhos. Essa especificidade da região é capturada, portanto, pela interação espaço-tempo. De julho a outubro de 2020, os valores nessas regiões caem e ficam próximos de 1, enquanto as regiões de saúde do interior se destacam com altos valores, sobretudo aquelas pertencentes ao DRS de São José do Rio Preto. Um efeito interessante é observado no ano de 2021, quando os valores de δ ficam próximos de 1, ou seja, com menor magnitude, em quase todas as regiões. Uma vez que as interações capturam as especificidades da situação da epidemia entre as regiões, no ano de 2021 o estado todo foi atingido de forma mais homogênea – como visto durante a análise exploratória – reduzindo assim a contribuição da interação espaço-tempo na explicação dos desfechos durante esse período.

Figura 11: Efeitos da interação espaço-tempo (δ) exponenciados para o modelo estatístico de casos de SRAG-COVID por Região de Saúde, a cada mês, no estado de São Paulo.

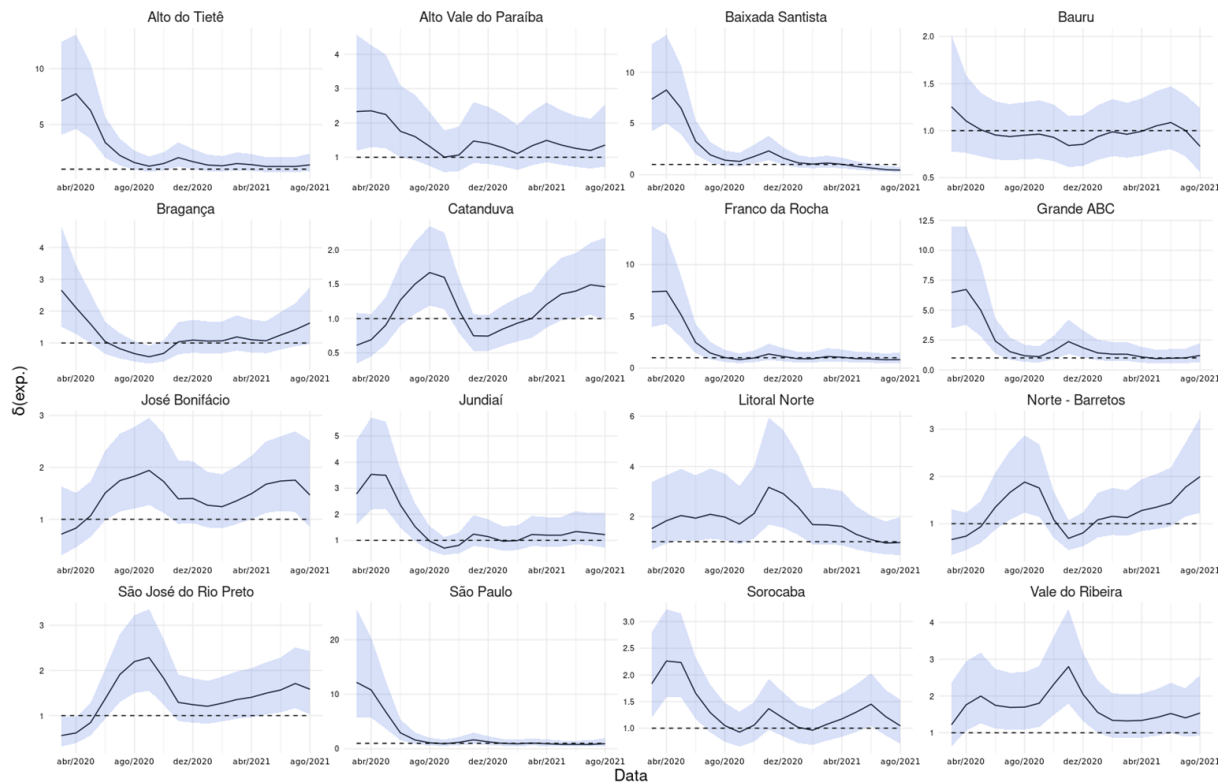


Também atribui-se destaque ao fato de que apesar de as regiões de saúde dentro de um mesmo DRS apresentarem similaridades, em alguns DRS houve divergência entre suas regiões, como é o caso dos DRS Sorocaba, Presidente Prudente e Bauru. Os efeitos da interação espaço-tempo para óbitos podem ser encontrados no apêndice A (Figura S7).

Essas mesmas interações podem ser representadas na forma de séries temporais entre cada região de saúde, como na Figura 12. Tais séries continuam representando as especificidades temporais entre cada região de saúde, que não são capturadas pelo efeito temporal global do modelo. Assim como na visualização em forma de mapas, percebe-se altos valores durante os primeiros meses para as regiões pertencentes aos DRS Grande São Paulo e Baixada Santista: Alto Tietê, Baixada Santista, Franco da Rocha, Grande ABC e São Paulo. Regiões fora da Grande São Paulo mas ainda com certa proximidade da capital, como Jundiaí e Sorocaba, apresentam um pico ainda nos primeiros meses, mas um pouco depois do que as regiões citadas anteriormente. Por fim, nota-se um claro protagonismo das regiões do interior a partir de julho de 2020: Catanduva, José Bonifácio e São José do Rio Preto (pertencentes ao DRS São José do Rio Preto) e Norte – Barretos (DRS Barretos) apresentam picos entre agosto

e setembro. Tais observações tornam mais nítido o processo de interiorização da doença. Outras regiões ao longo do estado apresentam comportamento específico, com picos em novembro de 2020, como o Vale do Ribeira (DRS Registro) e o Litoral Norte (DRS Taubaté).

Figura 12: Interações espaço-tempo (δ) exponenciadas para o modelo estatístico de casos de SRAG-COVID representadas na forma de séries temporais, por Região de Saúde, no estado de São Paulo.



Assim como visto no gráfico das interações em forma de mapa (Figura 11), a maioria das regiões de saúde possuem os intervalos de credibilidade da interação incluindo o valor 1 no ano de 2021, reforçando que tal componente teve menor impacto para explicação em tal ano.

Após descrever os resultados relativos aos componentes que capturaram a maior parte da variação dos desfechos espacial e temporalmente, agora trata-se dos efeitos relativos às covariáveis do modelo. Os efeitos exponenciados estão dispostos tanto na Tabela 5 como na Figura 13, e podem ser interpretados na forma de risco relativo. Em todos os modelos ajustados, o índice GeoSES apresentou coeficientes com estimativas maiores do que 1 quando exponenciados, e sem que o intervalo de credibilidade incluísse o valor 1. Isso implica que há uma tendência de que municípios de melhor índice socioeconômico apresentem maiores taxas de incidência e mortalidade por SRAG-COVID, mesmo após considerar os efeitos da hierarquia


urbana e vulnerabilidade social. Vê-se também que o efeito dessa variável teve maior magnitude para casos do que para óbitos. A inclusão da variável Proporção de Idosos resultou em uma redução na magnitude do efeito do GeoSES, embora ela mesma não tenha contribuído para explicação do desfecho.

Tabela 5: Efeitos exponenciados (estimativa pontual da média e intervalo de credibilidade de 95%). Valores cujo intervalo não contempla o valor 1 estão marcados em negrito.

Variável	Risco relativo (Intervalo de credibilidade 95%)	
	Desfecho: casos de SRAG-COVID	Desfecho: óbitos por SRAG-COVID
Intercepto	0,47 (0,38-0,58)	0,39 (0,31-0,48)
GeoSES	1,62 (1,40-1,86)	1,38 (1,20-1,58)
Hierarquia Urbana		
Município Rural	-	-
Município Urbano	1,08 (1,01-1,15)	1,07 (0,99-1,14)
Capital Regional	1,16 (1,03-1,29)	1,18 (1,06-1,32)
Metrópole	1,25 (0,99-1,58)	1,20 (0,96-1,49)
Atividade Frigorífica		
Não	-	-
Sim	1,08 (1,02-1,15)	1,08 (1,02-1,14)
IVS		
Baixo	-	-
Médio/Alto	0,94 (0,87-1,02)	0,97 (0,89-1,04)
Proporção de Idosos	1,01 (1-1,02)	1,01 (1-1,02)

IVS: Índice de Vulnerabilidade Social.

Figura 13: Efeitos das covariáveis ajustados e exponenciados para os modelos estatísticos de casos e óbitos de SRAG-COVID. Representa-se o valor pontual da média junto aos intervalos de credibilidade de 95%, em azul. Efeitos cujos intervalos não incluem o valor 1 estão marcados na cor vermelha.



Um gradiente entre as estimativas pontuais foi observado quando se trata das categorias de hierarquia urbana dos municípios. Assim, categorias mais altas dessa variável apresentaram, em média, maiores taxas de incidência e mortalidade por SRAG-COVID quando comparadas aos municípios rurais. A única categoria cujo intervalo incluiu o valor 1 em ambos os modelos foi metrópole, o que é condizente com as trajetórias inconstantes observadas durante a análise exploratória (Figura 7).

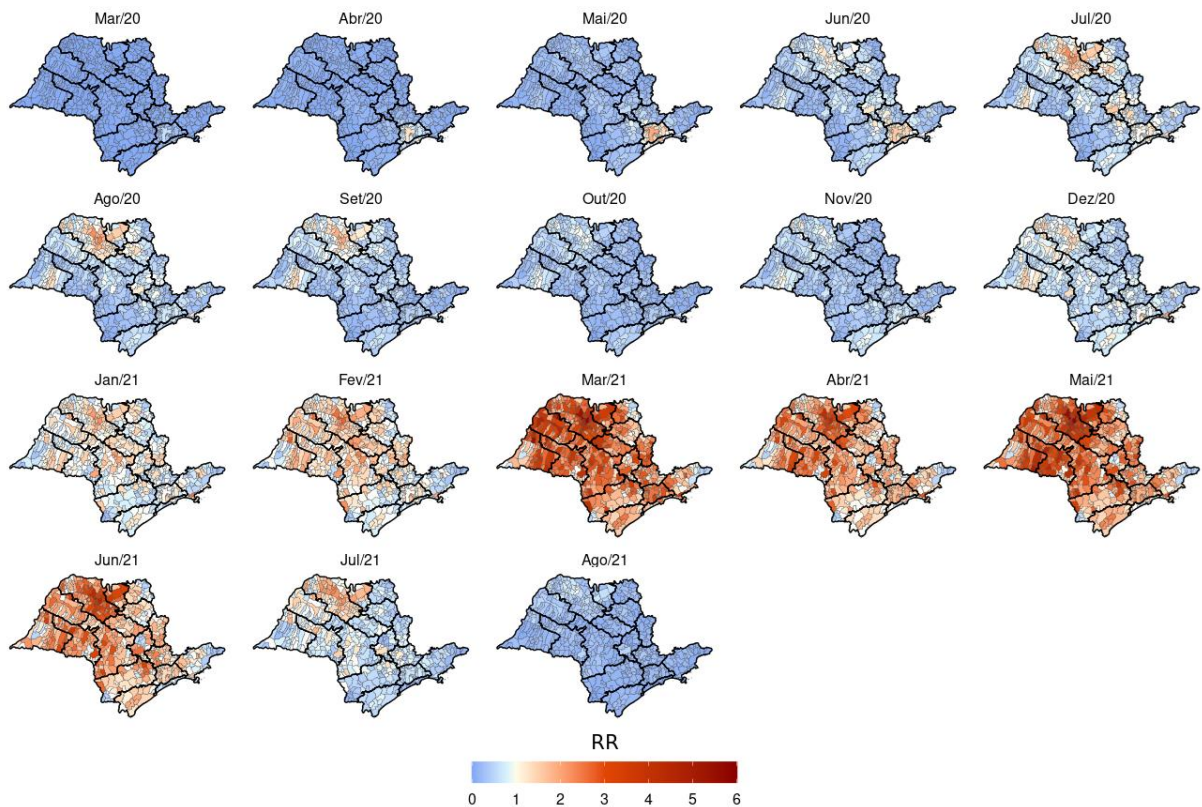
A presença de atividade frigorífica nos municípios se mostrou como um fator associado diretamente tanto à incidência quanto à mortalidade por SRAG-COVID. Os valores pontuais obtidos nos dois modelos se mostraram similares, de forma que um município possuir atividade frigorífica esteve associado com taxas de incidência e mortalidade 8% maiores em relação a municípios que não possuem, quando ajustado pelas outras covariáveis e condicionado pelo efeito espacial, temporal e espaço-temporal.

A inclusão da variável IVS não implicou numa melhora do ajuste do modelo. No

entanto, a mesma foi mantida por sua relevância teórica segundo o modelo teórico proposto. Em todos os modelos estatísticos em que foi incluída, apresentou estimativas pontuais de risco relativo menores do que 1, mas entre os modelos múltiplos, seu intervalo de credibilidade incluiu o valor 1.

Por fim, os riscos relativos para casos de SRAG-COVID estimados para cada município e mês, estão dispostos na Figura 14. Neste gráfico, é possível ver a conjunção entre os efeitos aleatórios descritos e as covariáveis na identificação de áreas e períodos de maior risco. É nítida a maior concentração de casos nos meses de 2021 no estado como um todo, como já havia se observado através dos efeitos temporais globais. Como também já identificado, os padrões espaciais de óbitos tendem a refletir os padrões espaciais de casos do mês anterior (Apêndice A, Figura S8), no entanto, há alguns padrões divergentes. Um gráfico similar, representando as probabilidades de cada município apresentar risco > 1 para casos e óbitos conforme proposto por Richardson e colaboradores (2004), se encontra no apêndice A (Figuras S9 e S10).

Figura 14: Risco relativo (RR) para casos de SRAG-COVID estimado pelo modelo estatístico (média) entre os municípios do estado de São Paulo em cada mês.




Novamente, os maiores riscos nos primeiros meses do estudo se concentram nos municípios da Grande São Paulo e Baixada Santista, e no interior os padrões passam a se manifestar de forma mais clara a partir de junho (casos) e julho (óbitos). De agosto a outubro os maiores riscos se concentram no Noroeste e Nordeste Paulista. Em 2021, o risco para casos e óbitos aumenta de forma a atingir patamares muito altos no estado como um todo. Os dois DRS que aparentam ter sido menos impactados neste ano são Taubaté e Franca, nas divisas do estado. Assim como se observou através dos indicadores LISA durante a análise exploratória (Figura 4), chama-se atenção para regiões que concentraram altos riscos para óbitos e não para casos, como o caso da região Nordeste do DRS Bauru e a região Oeste do DRS Sorocaba.

Os riscos relativos estimados passam a diminuir após o mês de maio até agosto de 2021, de forma que no último mês do estudo apenas os DRS de São José do Rio Preto e Barretos ainda permanecem com altos riscos de óbito.

A Figura 15 ilustra a variação da distribuição dos riscos relativos entre os municípios com e sem atividade frigorífica ao decorrer dos meses. Durante todo o período, municípios com atividade frigorífica apresentaram, no geral, maior risco relativo para casos de SRAG-COVID do que aqueles que não possuíam. Vê-se que a categoria “Não” sempre apresentou altos *outliers*, que podem corresponder principalmente às grandes cidades que não possuem atividade frigorífica mas mantiveram altas taxas. No entanto, o grupo com atividade frigorífica concentrou maiores riscos de forma geral.

Figura 15: Distribuição dos riscos relativos (RR) para casos de SRAG-COVID no estado de São Paulo estimados para os municípios com e sem atividade frigorífica ao longo dos meses do estudo.



7 DISCUSSÃO

7.1 DISTRIBUIÇÃO ESPAÇO-TEMPORAL DE SRAG-COVID EM SÃO PAULO

Com este trabalho, pôde-se extrair particularidades da forma com que os casos e óbitos por SRAG-COVID se distribuíram no estado de São Paulo, entre seus DRS, regiões de saúde e municípios ao longo dos meses de março de 2020 até agosto de 2021. Como apontado em outras análises de similares objetivos, viu-se que a distribuição da doença se deu de forma complexa e específica ao longo dos territórios, abarcando diferentes e concorrentes cenários ao longo do espaço e tempo (CASTRO et al., 2021a; GAMLIN et al., 2021; JOHNSON; RAVI; BRANEON, 2021).

Em um primeiro momento, observou-se que a epidemia atingiu majoritariamente os DRS Grande São Paulo (equivalente à Região Metropolitana de São Paulo – RMSP) e Baixada Santista nos três primeiros meses de estudo: março, abril e maio de 2020. A concentração de casos e óbitos nessas regiões durante esse período já havia sido relatada em prévias análises (ALCÂNTARA et al., 2020; DE ALMEIDA et al., 2020; DE SOUZA et al., 2020; LI et al., 2021; NAKADA; URBAN, 2021), e confirmou os padrões de dispersão previstos por Coelho (2020) ainda em março de 2020, que indicavam a dispersão da epidemia para as regiões mais próximas e conectadas à capital do estado, que foi o município de entrada da doença no país (DE SOUZA et al., 2020). Ribeiro (2020) também fornece plausibilidade a esses achados ao relatar a propensão dos municípios urbanos e grandes centros a se tornarem focos de infecção e apresentarem altos picos de casos doença logo após sua introdução no território, o que é concordante com as situações observadas em outros países como Alemanha e Estados Unidos (CARDOSO; GONÇALVES, 2020; STIER; BERMAN; BETTENCOURT, 2020).

Já entre junho e agosto do mesmo ano, observam-se padrões que remetem a um processo de interiorização da doença no estado. Ao longo desses três meses, os casos e óbitos na RMSP e Baixada Santista caem, enquanto os mesmos números nos DRS situados ao longo da rota ao interior do estado passam a subir. Entre esses, destacam-se: Piracicaba, Presidente Prudente, São José do Rio Preto, Barretos e Ribeirão Preto, sendo que nesses três primeiros é nítida a concentração dos casos entre os municípios da categoria “Capital Regional” desses DRS. Esse movimento rumo ao interior também foi descrito nos estudos de Almeida e colaboradores (2020), de Souza e colaboradores (2020), Fortaleza e colaboradores (2020b) e Castro e colaboradores (2021a). Castro e colaboradores (2021a) argumentam que o relaxamento das medidas de contenção implementadas em março no estado pode ter contribuído para esse

fenômeno. De fato, no período inicial a quarentena foi decretada em todo o estado (DE ALMEIDA et al., 2020), mas com a estabilização dos casos na Grande São Paulo, flexibilizações foram propostas seguindo o Plano São Paulo de Contingência (Plano SP), o que permitiu a retomada de algumas atividades e pode ter contribuído para o avanço da epidemia ao restante do estado (COSTA; COTA; FERREIRA, 2020). De Almeida e colaboradores (2020) justificam nesse mesmo sentido ao dizer que durante os primeiros meses da epidemia, os números de casos e óbitos nas regiões do interior não eram tão alarmantes, o que passou à população dessas regiões uma falsa sensação de segurança. Os autores inclusive relacionam, em seu estudo, os valores de número reprodutivo efetivo da doença (R_t) em cada DRS com as fases do Plano SP – que são classificadas como verde, azul, amarela, laranja ou vermelha, conforme a situação epidemiológica e disponibilidade regional de recursos nas regiões (GOVERNO DO ESTADO DE SÃO PAULO, 2020). Entre os DRS aqui citados como críticos nesse período no interior, todos apresentaram entrada na fase “vermelha” do plano em algum momento entre junho e setembro de 2020, com exceção de São José do Rio Preto (DE ALMEIDA et al., 2020). Esse achado é contraditório, uma vez que esse DRS foi, segundo nosso estudo, o que concentrou os municípios com maior risco relativo de casos entre julho e setembro.

Castro e colaboradores descreveram esses padrões de interiorização também para os outros estados do país (CASTRO et al., 2021a), que em maioria se deram pouco tempo depois do estado de São Paulo. A identificação de aglomerados de casos nas regiões mais centrais do país se deu em agosto e setembro, e no mês de outubro a distribuição dos casos já se dava de forma mais homogênea (não apenas concentrada em poucas cidades) entre todos os estados. Costa, Cota e Ferreira (2020) discutem preocupações existentes sobre o processo de interiorização da doença, uma vez que municípios menores e rurais apresentam menor disponibilidade de recursos relativos ao sistema de saúde. Os autores descrevem que uma situação a ser evitada é aquela em que a epidemia atinge níveis críticos no interior e nas capitais de forma simultânea, uma vez que a sobrecarga do sistema de saúde em ambas regiões traria piores desfechos para os municípios menores. Ribeiro e colaboradores (2020) destacam que, apesar dos grandes centros urbanos serem os primeiros a serem atingidos cronologicamente, ao comparar a situação epidêmica dos municípios a partir do dia do primeiro caso ou morte, os municípios menores tendem a passar por situações mais críticas – apresentar mais mortes por habitante – durante os seguintes quatro meses. Os autores apontam que para além da limitação de recursos, há uma diferença na composição etária desses municípios – os municípios menores têm, no geral, uma maior proporção de população idosa, grupo de maior risco para agravamento

da doença. A preocupação com os municípios menores e rurais também foi trazida a tona em outras análises espaço-temporais da doença nos Estados Unidos (PAUL et al., 2020, 2021), onde destacou-se a maior distribuição de comorbidades entre os habitantes destas regiões (CROSBY et al., 2012).

Enquanto outubro e novembro de 2020 consolidavam padrões de queda para os riscos de casos e óbitos em todo o estado respectivamente, no mês de dezembro a situação se inverteu. Os efeitos temporais globais ajustados mostraram um aumento do risco entre os dois desfechos, e esse atingiu patamares preocupantes durante o ano de 2021. Março se mostrou o pior mês, em termos de risco, para casos (RR pontual = 4,1) e abril o pior para óbitos (RR pontual = 4,79). Dessa forma, explicita-se a crítica situação do ano de 2021 em relação a 2020: foram 57,38% casos a mais e quase o dobro (aumento de 95,67%) de óbitos do que o ano anterior, mesmo representando um intervalo temporal menor. Já no mês de março, Castro e colaboradores (2021a) fizeram um apelo, alertando para o fato de naquela altura o Brasil já ter registrado um número de mortes por Covid-19 correspondente a 40% do total de 2020. Alguns fatores que podem ter contribuído para o preocupante patamar que o país e o estado de São Paulo atingiram em 2021 são: o relaxamento das medidas de contenção (CASTRO et al., 2021a), que se intensificou durante o período eleitoral em novembro de 2020 e foi sucedido por feriados de fim de ano e carnaval (SILVA; PENA, 2021); a chegada da variante P.1 (Gamma) (BANHO et al., 2021; BRIZZI et al., 2021; CASTRO et al., 2021a; SABINO et al., 2021), que até março de 2021, representava 66,2% das amostras no estado de São Paulo (SLAVOV et al., 2021); e a falsa sensação de segurança com o início da vacinação, em janeiro de 2021 (SILVA; PENA, 2021), que por muitos meses permaneceu em ritmo tímido principalmente por falta de esforços a nível federal.

Para além da alta magnitude dos efeitos temporais no ano de 2021, observa-se que as interações espaço-tempo tiveram valores muito próximos do valor nulo (1, quando exponenciadas). Entre janeiro e abril de 2021, apenas 8,3% das interações entre região de saúde e mês apresentaram intervalos de credibilidade sem o valor nulo; enquanto no ano todo de 2020, foram 31,74%. Uma vez que a presença de interações espaço-tempo relevantes pode ser interpretadas como “aglomerados de curta duração” (RICHARDSON et al., 2004; JOHNSON; RAVI; BRANEON, 2021), sua ausência indica uma maior homogeneidade entre os desfechos no período, que também é confirmada pelos menores valores de I de Moran global encontrados em 2021 (Apêndice A, Tabela S1). Ou seja, a conjunção desses fatores mostra que, em 2021, acontece o que foi alertado por Costa, Cota e Ferreira (2020): as situações tanto no interior quanto nas metrópoles se tornaram críticas simultaneamente, aumentando a probabilidade de

colapso dos sistemas de saúde e tendendo a elevar o número de óbitos. De fato, através de um cálculo direto, pode-se verificar que a letalidade hospitalar (HCFR) por SRAG-COVID em 2021 no estado foi de 31,22%, maior do que a de 25,1% encontrada em 2020. Volta-se atenção para regiões que nesse período apresentaram maior risco para óbitos do que para casos de SRAG-COVID, pois o mesmo pode ser um indício de uma situação crítica do sistema de saúde dos municípios envolvidos (GAMLIN et al., 2021). Observou-se que as regiões Nordeste do DRS Bauru e a região Oeste do DRS Sorocaba apresentaram esses padrões. Diversas análises espaço-temporais de fato optaram por utilizar como desfecho a letalidade (CFR) ou a própria HCFR, visto a relevância da identificação desses padrões que, podem ser diferentes ou opostos àqueles observados para casos e óbitos (BRIZZI et al., 2021; LORENZ et al., 2021; OROSZI et al., 2021).

Após os tenebrosos meses de março de abril, o risco relativo em todo o estado passou a cair, mas ainda mantendo um patamar muito alto até julho para casos e agosto para óbitos, quando se aproxima do valor 1. No geral, observou-se que os padrões encontrados na estrutura temporal entre os casos tendem a se repetir para os óbitos com uma margem de um mês de atraso, em média. Tal efeito é condizente com um estudo espaço-temporal semelhante realizado nos Estados Unidos (JOHNSON; RAVI; BRANEON, 2021), e com estudo retrospectivo realizado no Brasil com a mesma fonte de dados (RANZANI et al., 2021).

7.2 FATORES ASSOCIADOS À DISTRIBUIÇÃO

Em todos os modelos ajustados, encontrou-se associação direta entre o índice socioeconômico GeoSES e o número de casos e óbitos por SRAG-COVID nos municípios. Segundo os modelos finais, o aumento de 1 unidade no índice acarretaria em um aumento de 62% (I. Cred.: 40-86%) na incidência e de 38% (I. Cred.: 20-58%) na mortalidade pela síndrome. Tais efeitos tiveram sua magnitude reduzida com a introdução das demais covariáveis; no entanto, a direção de sua associação permaneceu positiva. Em um estudo realizado no município de São Paulo, Bermudi e colaboradores (2021) observaram uma mudança na associação entre o mesmo índice e a mortalidade por Covid-19: nas primeiras semanas da epidemia no município, as áreas de melhor condição socioeconômica concentravam os óbitos; três semanas depois em diante, a direção da associação se inverteu. Já Lorenz e colaboradores (2021), também no município de São Paulo mas com recorte temporal mais amplo, encontraram associação inversa entre renda per capita e óbitos por Covid-19. Os dois estudos, no entanto, trataram apenas do município de São Paulo e portanto trabalharam com

menores níveis de agregação – os distritos administrativos e as unidades de desenvolvimento humano (UDHs), respectivamente. Assim, argumenta-se que a direção do efeito de variáveis que caracterizam condições socioeconômicas em desfechos de saúde pode ser diferente dependendo da unidade de análise.

Já Li e colaboradores (2021) realizaram estudo similar, agora tendo os municípios do estado de São Paulo como unidade de análise. Nele, os autores identificaram renda per capita e escolaridade como fatores inversamente associados a hospitalizações por SRAG-COVID nos municípios. Argumenta-se que esse caráter inverso das associações relatadas pode ter sido atingido após controle por covariáveis relevantes porém não incluídas em nosso estudo, como o índice de Gini e densidade populacional. Apesar do índice GeoSES ser um indicador que se propõe a mensurar dimensões de desigualdade, como segregação e privação material, todas essas informações são representadas neste trabalho pelo mesmo índice. Além disso, o estudo de Li e colaboradores envolveu um recorte temporal menor: de abril a junho de 2020. Nosso estudo envolveu 15 meses a mais, e pode portanto representar diferentes padrões de associação entre as covariáveis e o desfecho. Outras análises pelo Brasil também apontaram associação ou coincidência espacial entre áreas mais ricas e desfechos de Covid-19, mas todas também se restringiram ao período inicial da pandemia (DE SOUZA; MACHADO; DO CARMO, 2020; CESTARI et al., 2021; QUININO et al., 2021).

Um município abriga diversos contextos socioeconômicos e realidades dentro de si próprio (ALBUQUERQUE; RIBEIRO, 2021), que, nesse estudo, são sumarizados em um único valor através do índice GeoSES. Os municípios urbanos de maior renda, conectividade, e que concentram os serviços e atividades comerciais mantiveram condições propícias para a circulação do vírus (RIBEIRO et al., 2020), além de também produzirem “pobreza, carências e contradições” (ALBUQUERQUE; RIBEIRO, 2021). Dessa forma justifica-se também os achados relativos à hierarquia urbana dos municípios, onde, tratando de estimativas pontuais, encontrou-se um gradiente de risco: quanto mais alta a categoria de hierarquia do município, maiores os aumentos esperados nas taxas de incidência e mortalidade quando comparados aos municípios rurais que, apesar do processo de interiorização, foram os menos atingidos. Resultados semelhantes foram encontrados em outros estudos: Paul e colaboradores (2021) identificaram associação entre ruralidade e menores taxas de incidência e mortalidade por Covid-19 através de estudo espaço-temporal entre março e abril de 2020 nos Estados Unidos; Fortaleza e colaboradores (2020b) encontraram gradiente semelhante relativo à hierarquia dos municípios durante os primeiros meses da epidemia em São Paulo; e outros já apontavam maiores taxas em regiões urbanas e metropolitanas de cidades brasileiras nesse período

(CESTARI et al., 2021; LI et al., 2021; NAKADA; URBAN, 2021; QUININO et al., 2021).

Albuquerque e Ribeiro (2021) destacam, no entanto, que apesar desses municípios concentrarem mais casos, estes também possuem maior capacidade de resposta em termos de recursos, ofertas de serviços, e disponibilidade de profissionais, leitos e respiradores (PORTELA et al., 2020). Tal afirmação é uma possível explicação para a menor magnitude dos riscos relativos das variáveis GeoSES e hierarquia urbana para óbitos do que de casos de SRAG-COVID em nosso estudo. Gamlin e colaboradores (2021) também criticam a tentativa de entendimento da pandemia através apenas de indicadores como incidência e mortalidade, uma vez que municípios menores que aparentam ter poucos óbitos na verdade podem estar lidando com uma situação mais crítica com níveis de letalidade mais altos do que as metrópoles e grandes centros. Esse fenômeno já pôde ser observado em estudos como o de Oroszi e colaboradores (2021), na Hungria, onde foi encontrada associação inversa entre o índice de privação e incidência de Covid-19, mas os padrões se inverteram ao tratar de letalidade. Apesar do presente estudo não tratar de HCFRs, durante a análise exploratória foi possível verificar que os padrões encontrados entre as covariáveis GeoSES, IVS e Hierarquia Urbana e os desfechos de casos e óbitos se invertem ao analisar HCFR (Apêndice A, Figura S4). Apesar de outros estudos indicarem que a subnotificação de casos pode ser o que realmente superestima a letalidade nessas regiões (LORENZ et al., 2021; PAIXÃO et al., 2021), acredita-se que esse fator tem menor influência ao tratar de casos de SRAG-COVID.

Apesar do amplo reconhecimento das populações vulnerabilizadas como alvos de maior preocupação para desfechos de Covid-19 (COELHO et al., 2020; ALBUQUERQUE; RIBEIRO, 2021; GAMLIN et al., 2021; MAESTRIPIERI, 2021; MATTA et al., 2021; RIBEIRO et al., 2021), a relação entre índices de vulnerabilidade social e as taxas da doença nos território em nível ecológico têm sido inconsistentes (JOHNSON; RAVI; BRANEON, 2021; NEELON et al., 2021). No Estados Unidos, encontrou-se associações diretas entre o índice de vulnerabilidade e maiores taxas de incidência e mortalidade (KARAYE; HORNEY, 2020; KHAZANCHI et al., 2020), associações somente com a letalidade (NAYAK et al., 2020), e associações que variavam no espaço (WANG et al., 2020) e no tempo (JOHNSON; RAVI; BRANEON, 2021; NEELON et al., 2021). Em nosso estudo, também observou-se uma inversão ao longo do tempo durante a análise exploratória, onde as maiores taxas prevaleciam entre os municípios de maior vulnerabilidade até o mês de agosto, quando em paralelo ao processo de interiorização, aqueles com baixa vulnerabilidade passaram a apresentar as maiores taxas.

Tais resultados podem ser explicados pela concentração dos municípios com maior

vulnerabilidade nas periferias do estado, como no sudoeste das regiões de Presidente Prudente, Sorocaba e Registro; além da Grande São Paulo. Com os primeiros casos e óbitos ocorrendo em municípios dessa última, as taxas eram maiores para os municípios considerados vulneráveis no momento inicial, e o espalhamento da doença para o interior e outras regiões contribuiu para essa inversão. Nos modelos ajustados não foram encontradas associações entre o IVS – em sua forma contínua ou categorizada – e os desfechos quando se tratou de modelos múltiplos. Essa não associação já havia sido relatada em outros estudos que utilizaram o índice no Brasil, no período inicial de pandemia (DE SOUZA; MACHADO; DO CARMO, 2020; SCHNEIDER et al., 2020), mas houve associação direta no estudo espacial de Castro e colaboradores (2021b), quando controlou-se por outros preditores como IDH, densidade populacional, renda per capita e outros. Questiona-se se os resultados persistiriam ao utilizar a letalidade hospitalar como desfecho, uma vez que os DRS Registro e o sudoeste de Sorocaba se destacaram por apresentarem altas taxas de óbitos e não de casos em 2021, e são regiões de alta vulnerabilidade.

7.3 O PAPEL DOS FRIGORÍFICOS

Em todos os modelos ajustados, encontrou-se associações positivas entre a presença de atividade frigorífica e os desfechos de SRAG-COVID nos municípios. Essas associações se mantiveram mesmo após o controle pelas demais covariáveis: índice socioeconômico, vulnerabilidade social, hierarquia urbana e proporção de idosos. Dessa forma, pode-se interpretar que entre dois municípios similares em que o único ponto que diferem é a presença de atividade frigorífica, aquele que possui tende a apresentar incidência e mortalidade 8% maiores do que aquele que não possui. Embora a coincidência espacial entre os frigoríficos e a distribuição da Covid-19 já tenha sido relatada na literatura (HECK et al., 2020; NASCIMENTO; TOMBINI; RIPPLINGER, 2020; SERRA; OLIVEIRA, 2020; SILVEIRA et al., 2020), esse é o primeiro estudo até onde se sabe a apontar associação estatística em nível ecológico entre a variável e os desfechos da doença.

Conforme descrito por Albuquerque e Ribeiro (2021), assim como Silveira e colaboradores (2020), os espaços “luminosos” – os centros e metrópoles que apresentam maior urbanização, riquezas, atividades econômicas e densidade populacional – tendem a concentrar os primeiros focos da Covid-19, e posteriormente são atingidos municípios menores mas que concentram atividades produtivas, como mineração e agropecuária, que apesar de serem atrativos para população que procura trabalho, não apresentam melhora nas condições de vida

para as famílias (ALBUQUERQUE; RIBEIRO, 2021). Esse fenômeno pode ser observado na Figura 15, onde a partir de maio de 2020 – período em que o processo de interiorização se consolida – os riscos relativos estimados passam a ser consistentemente maiores nos municípios com atividade frigorífica do que aqueles sem. Assim, observa-se que municípios de menor expressão hierárquica passam a concentrar a doença, o que Albuquerque e Ribeiro (2021) descrevem como uma fuga da difusão através da hierarquia urbana clássica. Esse fenômeno foi frequentemente relatado na Região Sul do Brasil, onde municípios menores como Lajeado e Encantado, no RS, que possuem atividade frigorífica, se destacaram por passarem a apresentar as maiores incidências do estado entre maio e junho de 2020 (SILVEIRA et al., 2020; GRANADA et al., 2021). Tais relatos vão de encontro ao observado durante a análise exploratória (Figura 8), onde no ano de 2020 o fato do município possuir atividade frigorífica implicava em maiores incidências de SRAG-COVID somente entre aqueles de menor hierarquia e menor índice socioeconômico. Ou seja, os municípios que concentravam essas atividades apresentaram maiores taxas do que era esperado para sua categoria hierárquica.

Tais achados contribuem para a compreensão do papel dos territórios de degradação do trabalho (HECK et al., 2020) – neste caso, os frigoríficos – na distribuição espacial e no processo de interiorização da doença, em nível ecológico. Complementa-se o que já havia sido observado em outros estudos pelo Brasil: Heck e colaboradores (2020) haviam observado que os padrões espaciais da doença em seu movimento para o interior dos estados da Região Sul coincidiram com a presença de frigoríficos nos municípios e seus vizinhos. Ainda na Região Sul, Nascimento e colaboradores (2020) também destacaram a influência do trabalho agroindustrial sobre os surtos registrados em frigoríficos e o aumento no número de casos na Mesorregião Grande Fronteira Mercosul; e Silveira e colaboradores (2020) apontaram o papel que não só os frigoríficos, mas também toda a rede de fluxos envolvida na cadeia de produção de carnes exerceram sobre a disseminação da doença na região de Lagos, no RS. Resultado similar foi obtido em estudo no sul e sudoeste do estado do Pará, onde Serra e Oliveira (2020) encontraram associações significativas que mostravam que o número de trabalhadores em abate de bovinos nessas regiões se relacionava de forma inversa com o índice de isolamento social e direta com o número de casos e óbitos por Covid-19.

Os resultados fortalecem a caracterização da Covid-19 como uma doença relacionada ao trabalho (MAENO, 2021). De fato, verificou-se em países da Europa diferenças consideráveis na prevalência da doença entre os grupos de trabalhadores. Na Itália, Modonese e colaboradores (2021) mostraram em estudo de soroprevalência que, após os profissionais da saúde, os trabalhadores de frigoríficos estavam entre os grupos que apresentaram maior

prevalência da doença. Rivera Ariza (RIVERA ARIZA et al., 2021) e colaboradores também destacam, na Espanha, o alto número de surtos institucionais que ocorrem nesses estabelecimentos. No Brasil, Maeno (2021) mostra que ao verificar dados da Previdência Social, houve um estrondoso salto nas doenças por vírus notificados como relacionados ao trabalho em 2020, sendo que entre as ocupações externas à área da saúde, os magarefes (trabalhadores de frigoríficos) estão entre os que mais apresentaram ocorrências (MINISTÉRIO DO TRABALHO, 2021).

Além do ambiente propício para transmissão nos locais de trabalho e negligência das empresas na imposição de medidas protetivas (DE CAMPOS SILVA, 2020; FRENCH NATIONAL ACADEMY OF MEDICINE, 2020; PINA, 2020), os trabalhadores de frigoríficos são marcados como populações com alta vulnerabilidade socioeconômica e baixas condições de moradia e transporte (DE CAMPOS SILVA, 2020; FRENCH NATIONAL ACADEMY OF MEDICINE, 2020; GRANADA et al., 2021). Granada e colaboradores (2021) também ressaltam outras complicações entre aqueles trabalhadores que são imigrantes, como maior dificuldade no acesso a serviços de saúde.

A negligência e invisibilização pela qual esses trabalhadores passam é notável através do fato de que são, desde o início da pandemia, tratados como trabalhadores essenciais. No entanto, questiona-se tal essencialidade uma vez que a manutenção de seus esforços não implicaram na garantia do direito à alimentação da população. Maeno (2021) mostrou que, segundo dados da Associação Brasileira de Frigoríficos (ABRAFRIGO, 2021), em oito dos doze meses de 2020 as exportações de carne bovina superaram os números de 2019, e em março e abril de 2021, o faturamento para tais meses foi respectivamente 12% e 23% superior aos mesmos períodos no ano anterior. Nos mesmos dois anos, no entanto, observou-se o aumento de quase 9 milhões de brasileiros (aumento de 85% em relação a 2018) na situação de fome (PENSSAN, 2021), junto ao aumento de 30,8% em 12 meses no preço da carne bovina no país (IBGE, 2021) e o menor número de consumo em 26 anos (CONAB, 2021), assim como o registro de cenas de busca por outros cortes antes desprezados e filas para comprar ossos e restos de carne bovina (“Retratos da fome no Brasil”, 2021). Assim, observa-se que a essencialidade de tais trabalhadores não serve à população. Assim como Heck (2020) aponta em seu texto: “Não se trata de alimentar o mundo, como dizem os proprietários e agentes do crescimento econômico, mas de manter os patamares de acumulação e da produção, mesmo que para isso seja exigido colocar a saúde do/a trabalhador/a em risco”. Maeno (2021) e Cerrutti (2021) discutem portanto a definição da essencialidade do trabalho, e Granada e colaboradores (2021) apontam que a produção e o lucro são tratados como essenciais, mas as pessoas

envolvidas são tratadas com mínima prioridade – são consideradas descartáveis.

7.4 LIMITAÇÕES E TRABALHOS FUTUROS

O estudo apresenta limitações e ressalvas. Através do modelo teórico apresentado, é clara a complexidade das relações entre os fatores que determinam a distribuição espaço-temporal da Covid-19 entre os municípios. Assim, buscou-se tratar de fatores socioeconômicos e demográficos, e avaliar o impacto de um aspecto específico ainda não profundamente explorado na modelagem estatística da Covid-19: a vulnerabilidade do trabalho, expressa através do trabalho nos frigoríficos. Portanto, ao interpretar as associações obtidas, deve-se levar em conta que outros fatores não incluídos na modelagem são também importantes e estão envolvidos no complexo processo de determinação.

Entre esses fatores, alguns muito comuns e presentes em outras análises na literatura são a densidade populacional e o acesso à saúde. Embora tenham sua importância reconhecida através do modelo teórico, tais variáveis relacionam-se com outras já incluídas no estudo: a hierarquia urbana, que busca sumarizar fatores relativos à conectividade, demografia e urbanização dos municípios através da combinação de duas classificações do IBGE (2017, 2018b), tem em si expressa a densidade populacional dos municípios. De forma similar, municípios de maior hierarquia urbana e melhores índices socioeconômicos tendem a apresentar maior cobertura do SUS e melhor acesso à saúde (Figura 6c). Assim, optou-se pela parcimônia ao não incluir tais variáveis explicitamente no modelo, mas reconhecendo que participam no processo de determinação. No entanto, é evidente que a inclusão de mais variáveis e a verificação da mudança nos efeitos obtidos contribuiria com o entendimento das associações, o que pode ser explorado em estudos futuros.

Outro fator frequentemente apontado como forte atuante na distribuição de casos e óbitos por Covid-19 é o cenário político nos municípios (ALBUQUERQUE; RIBEIRO, 2021; GAMLIN et al., 2021). É reconhecido o impacto que as diferentes respostas políticas à epidemia exercem sobre os desfechos da doença (HENRIQUES; VASCONCELOS, 2020). Tais fatores influenciam a alocação de recursos (ISMAIL et al., 2021), a adoção de medidas não farmacológicas e sua influência sobre a percepção da população sobre a situação (PEREIRA; OLIVEIRA; SAMPAIO, 2020), e a adoção de medidas não eficazes contra a Covid-19, como a promoção do uso de cloroquina por parte do Governo Federal (BARBERIA; GÓMEZ, 2020; CASTRO et al., 2021a). Assim, a inclusão de uma variável ao modelo estatístico que envolva esse contexto político pode ajudar a compreender a situação de municípios *outliers*, como

aqueles que se destacam pelo alto número de casos e óbitos em relação aos seus vizinhos e sua região. Um exemplo encontrado durante este estudo é o município de Porto Feliz, no DRS Sorocaba, que entre maio e julho de 2020 figurou entre os maiores riscos relativos do estado para casos, enquanto seus vizinhos não apresentavam altas taxas. Tem-se notado, no entanto, a referência que o município se tornou na aplicação do “kit covid” para tratamento dos casos da doença (NASCIMENTO, 2021), o que sugere que a inclusão desses contextos e fatores políticos pode ter relevância na explicação dos desfechos da Covid-19 em estudos futuros.

Para além disso, já observou-se que a pandemia afetou diferentemente os grupos populacionais de acordo com raça/cor, classe, gênero, idade, e suas combinações (MAESTRIPIERI, 2021). Assim como outros estudos (JOHNSON; RAVI; BRANEON, 2021), apesar de considerar a proporção de idosos no modelo para atenuar as diferenças etárias entre os municípios, as taxas não são ajustadas por idade. Uma abordagem onde a estrutura etária do município é levada em conta é preferível (LAWSON, 2013a) e foi empregada no estudo de Lorenz e colaboradores (2021), onde foram utilizados valores esperados padronizados por idade e sexo. Pretende-se incorporar tais fatores em próximas análises.

Apesar de ser um dos primeiros estudos a incorporar uma variável relacionada à atividade frigorífica em um modelo estatístico para Covid-19, tal fator traz consigo uma série de limitações. Os dados extraídos da RAIS, além de não contemplarem emprego informal, podem conter mais de um registro referente ao mesmo indivíduo. Outro problema é que foi necessária a categorização da variável por conta de sua distribuição extremamente assimétrica em sua forma contínua. Assim, além da dependência da definição de um ponto de corte, não são levadas em conta diferenças entre a intensidade da atividade nos municípios. Ou seja, se um município apresentar 2 trabalhadores de frigorífico a cada 1.000 ou 10 a cada 1.000, ele pertencerá à mesma categoria. Por fim, reconhece-se pela literatura o impacto dos frigoríficos não somente para o município sede dessas instalações, mas também para seus vizinhos (GEMELLI; CARVALHAL, 2011; HECK et al., 2020; SILVEIRA et al., 2020; GRANADA et al., 2021). Assim, espera-se que em futuros estudos possa-se contemplar essa relação de dependência espacial de diferentes formas, incluindo dados de deslocamento pendular, por exemplo.

8 CONSIDERAÇÕES FINAIS

O estudo contribuiu, portanto, para a descrição da dinâmica espaço-temporal da Covid-19 no estado de São Paulo, apontando períodos e regiões de maior concentração de hospitalizações e óbitos, além de voltar a atenção aos municípios que tiveram esses padrões divergentes. Traz-se destaque também aos fatores estruturais condicionantes dessa distribuição, e à um “sintoma” em específico – as condições de trabalho nos frigoríficos. Dessa forma, buscou-se evidenciar a precária e invisibilizada situação desses trabalhadores, que em muitos casos têm essa ocupação como sua única opção de trabalho. As contradições da dinâmica de produção desse sistema ficam evidentes, e como apontaram Albuquerque e Ribeiro (2021), a pandemia de Covid-19 está marcada não só pelas desigualdades de acesso a recursos e serviços de saúde, mas também pela perversidade da seletividade – que envolve raça/cor, gênero, classe e território – daqueles que têm suas vidas colocadas em risco em nome da manutenção do lucro e dos patamares de acumulação.

REFERÊNCIAS

- ABD NAEEM, N. S.; ABDUL RAHMAN, N. Estimating relative risk for dengue disease in Peninsular Malaysia using INLA. **Malaysian Journal of Fundamental and Applied Sciences**, v. 13, n. 4, p. 721–727, 26 dez. 2017.
- ABELLAN, J. J.; RICHARDSON, S.; BEST, N. Use of space-time models to investigate the stability of patterns of disease. **Environmental Health Perspectives**, v. 116, n. 8, p. 1111–1119, ago. 2008.
- ABIEC. **Perfil da pecuária no Brasil: Relatório Anual**. Brasília: Associação Brasileira das Indústrias de Exportação de Carne, 2018. . Acesso em: 25 nov. 2021.
- ABRAFRIGO. **Estatísticas: Exportação**. Disponível em: <<https://www.abrafrigo.com.br/index.php/estatisticas/>>. Acesso em: 27 dez. 2021.
- ACHCAR, J. A. et al. Use of Poisson spatiotemporal regression models for the Brazilian Amazon Forest: malaria count data. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 44, p. 749–754, dez. 2011.
- AHMED, F. et al. Why inequality could spread COVID-19. **The Lancet Public Health**, v. 5, n. 5, p. e240, 1 maio 2020.
- AIDALA, A. A. et al. Housing Status, Medical Care, and Health Outcomes Among People Living With HIV/AIDS: A Systematic Review. **American Journal of Public Health**, v. 106, n. 1, p. e1–e23, jan. 2016.
- ALBUQUERQUE, M. V. DE; RIBEIRO, L. H. L. Inequality, geographic situation, and meanings of action in the COVID-19 pandemic in Brazil. **Cadernos De Saude Publica**, v. 36, n. 12, p. e00208720, 2021.
- ALCÂNTARA, E. et al. Investigating spatiotemporal patterns of the COVID-19 in São Paulo State, Brazil. **Geospatial Health**, v. 15, n. 2, 26 nov. 2020.
- ALLAIRE, J. RStudio: integrated development environment for R. **Boston, MA**, v. 770, n. 394, p. 165–171, 2012.
- ALMEIDA ANDRADE, L. et al. Spatiotemporal Pattern of COVID-19-Related Mortality during the First Year of the Pandemic in Brazil: A Population-based Study in a Region of High Social Vulnerability. **The American Journal of Tropical Medicine and Hygiene**, p. tpmd210744, 10 nov. 2021.
- ANDRADE, L. A. et al. COVID-19 mortality in an area of northeast Brazil: epidemiological characteristics and prospective spatiotemporal modelling. **Epidemiology and Infection**, v. 148, p. e288, 1 dez. 2020.
- ANSELIN, L. Local Indicators of Spatial Association—LISA. **Geographical Analysis**, v. 27, n. 2, p. 93–115, 1995.
- ANSELIN, L. Exploratory spatial data analysis in a geocomputational environment. **Geocomputation: A Primer**. Chichester New York: Wiley, 1998.

ANTUNES, R. L. **Adeus ao trabalho? Ensaio sobre as metamorfoses e a centralidade do mundo do trabalho**. 3. ed ed. São Paulo: Cortez [u.a.], 1995.

ANTUNES, R.; PRAUN, L. A sociedade dos adoecimentos no trabalho. **Serviço Social & Sociedade**, p. 407–427, set. 2015.

AUCHINCLOSS, A. H. et al. A review of spatial methods in epidemiology, 2000-2010. **Annual Review of Public Health**, v. 33, p. 107–122, abr. 2012.

BAILEY, T. C. Spatial statistical methods in health. **Cadernos de Saúde Pública**, v. 17, n. 5, p. 1083–1098, out. 2001.

BAKKA, H. et al. Spatial modeling with R-INLA: A review. **WIREs Computational Statistics**, v. 10, n. 6, p. e1443, 2018.

BANHO, C. A. et al. **Effects of SARS-CoV-2 P.1 introduction and the impact of COVID-19 vaccination on the epidemiological landscape of São José Do Rio Preto, Brazil**. [s.l: s.n.]. Disponível em: <<https://www.medrxiv.org/content/10.1101/2021.07.28.21261228v1>>. Acesso em: 19 dez. 2021.

BAQUERO, O. S. **INLAOutputs: process selected outputs from the ‘INLA’Package**. . Acesso em: 9 nov. 2020.

BAQUI, P. et al. Ethnic and regional variations in hospital mortality from COVID-19 in Brazil: a cross-sectional observational study. **The Lancet Global Health**, v. 8, n. 8, p. e1018–e1026, 1 ago. 2020.

BARATA, R. B. **Como e por que as desigualdades sociais fazem mal à saúde**. 1. ed ed. Rio de Janeiro: Fiocruz, 2009.

BARBERIA, L. G.; GÓMEZ, E. J. Political and institutional perils of Brazil’s COVID-19 crisis. **The Lancet**, v. 396, n. 10248, p. 367–368, 8 ago. 2020.

BARROZO, L. V. et al. GeoSES: A socioeconomic index for health and social research in Brazil. **PLOS ONE**, v. 15, n. 4, p. e0232074, 29 abr. 2020.

BASTOS, L. S. et al. COVID-19 e hospitalizações por SRAG no Brasil: uma comparação até a 12^a semana epidemiológica de 2020. **Cadernos de Saúde Pública**, v. 36, n. 4, p. e00070120, 2020.

BASTOS, L. S. **Hospitalizações por SRAG como proxy para casos graves de Covid-19 no Brasil**Belo Horizonte, 17 jun. 2020. Disponível em: <<https://www.youtube.com/watch?v=eZmWtCFceco>>. Acesso em: 7 maio. 2021

BERMUDI, P. M. M. et al. Spatiotemporal ecological study of COVID-19 mortality in the city of São Paulo, Brazil: Shifting of the high mortality risk from areas with the best to those with the worst socio-economic conditions. **Travel Medicine and Infectious Disease**, v. 39, p. 101945, 1 jan. 2021.

BERNARDINELLI, L. et al. Bayesian analysis of space—time variation in disease risk. **Statistics in Medicine**, v. 14, n. 21–22, p. 2433–2443, 1995.

- BESAG, J. Spatial Interaction and the Statistical Analysis of Lattice Systems. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 36, n. 2, p. 192–225, jan. 1974.
- BESAG, J.; YORK, J.; MOLLIÈ, A. Bayesian image restoration, with two applications in spatial statistics. **Annals of the Institute of Statistical Mathematics**, v. 43, n. 1, p. 1–20, 1 mar. 1991.
- BEST, N.; RICHARDSON, S.; THOMSON, A. A comparison of Bayesian spatial models for disease mapping. **Statistical Methods in Medical Research**, v. 14, n. 1, p. 35–59, 1 fev. 2005.
- BILAL, U. et al. Spatial Inequities in COVID-19 Testing, Positivity, Confirmed Cases, and Mortality in 3 U.S. Cities. **Annals of Internal Medicine**, 30 mar. 2021.
- BIVAND, R. et al. Package ‘spdep’. **The Comprehensive R Archive Network**, 2015.
- BIVAND, R.; PEBESMA, E. J.; GÓMEZ-RUBIO, V. Areal Data and Spatial Autocorrelation. In: **Applied spatial data analysis with R**. Use R! New York: Springer, 2008. p. 237–272.
- BLANGIARDO, M. et al. Spatial and spatio-temporal models with R-INLA. **Spatial and Spatio-temporal Epidemiology**, v. 4, p. 33–49, 1 mar. 2013.
- BLANGIARDO, M.; CAMELETTI, M. **Spatial and spatio-temporal Bayesian models with R-INLA**. Chichester, West Sussex: John Wiley and Sons, Inc, 2015.
- BRIZZI, A. et al. **Report 46: Factors driving extensive spatial and temporal fluctuations in COVID-19 fatality rates in Brazilian hospitals**. [s.l.] Epidemiology, 2 nov. 2021. Disponível em: <<http://medrxiv.org/lookup/doi/10.1101/2021.11.01.21265731>>. Acesso em: 11 nov. 2021.
- BUCCHIANERI, G. W. Is SARS a Poor Man’s Disease? Socioeconomic Status and Risk Factors for SARS Transmission. **Forum for Health Economics & Policy**, v. 13, n. 2, 22 jul. 2010.
- CARDOSO, B.-H. F.; GONÇALVES, S. Urban Scaling of COVID-19 epidemics. **arXiv:2005.07791 [physics, q-bio]**, 15 maio 2020.
- CARMO, M. E. DO; GUIZARDI, F. L. O conceito de vulnerabilidade e seus sentidos para as políticas públicas de saúde e assistência social. **Cadernos de Saúde Pública**, v. 34, 26 mar. 2018.
- CARPENTER, T. E. The spatial epidemiologic (r)evolution: a look back in time and forward to the future. **Spatial and Spatio-Temporal Epidemiology**, v. 2, n. 3, p. 119–124, set. 2011.
- CARROLL, R. et al. Comparing INLA and OpenBUGS for hierarchical Poisson modeling in disease mapping. **Spatial and Spatio-temporal Epidemiology**, v. 14–15, p. 45–54, 1 jul. 2015.
- CARVALHO, L.; PIRES, L. N.; XAVIER, L. D. L. COVID-19 e Desigualdade no Brasil. 2020.
- CASTRO, M. C. et al. Spatiotemporal pattern of COVID-19 spread in Brazil. **Science**, 14 abr. 2021a.
- CASTRO, R. R. et al. Spatial dynamics of the COVID-19 pandemic in Brazil. **Epidemiology and Infection**, v. 149, p. e60, 25 fev. 2021b.

CDC. **Coronavirus Disease 2019 (Covid-19)**. Disponível em: <<https://www.cdc.gov/coronavirus/2019-ncov/faq.html>>. Acesso em: 2 mar. 2021.

CERUTTI, F. M. O trabalho essencial na pandemia. mar. 2021.

CESTARI, V. R. F. et al. Social vulnerability and COVID-19 incidence in a Brazilian metropolis. **Ciencia & Saude Coletiva**, v. 26, n. 3, p. 1023–1033, mar. 2021.

CHAPARINI, M. **Frigoríficos são principal foco de contágios na região**. Disponível em: <<https://grupoahora.net.br/conteudos/2020/04/25/frigorificos-sao-principal-foco-de-contagios-na-regiao/>>. Acesso em: 10 jan. 2022.

CHEN, J. T.; KRIEGER, N. Revealing the Unequal Burden of COVID-19 by Income, Race/Ethnicity, and Household Crowding: US County Versus Zip Code Analyses. **Journal of public health management and practice: JPHMP**, v. 27 Suppl 1, COVID-19 and Public Health: Looking Back, Moving Forward, p. S43–S56, fev. 2021.

CLAYTON, D. Generalized linear mixed models. In: GILKS, W. R.; RICHARDSON, S.; SPIEGELHALTER, D. J. (Eds.). . **Markov chain Monte Carlo in practice**. Boca Raton, Fla: Chapman & Hall, 1998.

CLEVELAND, W. S.; GROSSE, E.; SHYU, W. M. Local regression models. In: **Statistical Models in S**. [s.l.] Wadsworth & Brooks/Cole, 1992.

COELHO, F. C. et al. Assessing the spread of COVID-19 in Brazil: Mobility, morbidity and social vulnerability. **PloS One**, v. 15, n. 9, p. e0238214, 2020.

CONAB. **Histórico mensal de carne bovina**. Disponível em: <<https://www.conab.gov.br/info-agro/analises-do-mercado-agropecuaria-e-extrativista/analises-do-mercado/historico-mensal-de-carne-bovina>>. Acesso em: 27 dez. 2021.

CORBURN, J. et al. Slum Health: Arresting COVID-19 and Improving Well-Being in Urban Informal Settlements. **Journal of Urban Health: Bulletin of the New York Academy of Medicine**, v. 97, n. 3, p. 348–357, jun. 2020.

CORDES, J.; CASTRO, M. C. Spatial analysis of COVID-19 clusters and contextual factors in New York City. **Spatial and Spatio-temporal Epidemiology**, v. 34, p. 100355, ago. 2020.

COSTA, A. C. C. et al. Surveillance of dengue vectors using spatio-temporal Bayesian modeling. **BMC Medical Informatics and Decision Making**, v. 15, n. 1, p. 93, 13 nov. 2015.

COSTA, G. S.; COTA, W.; FERREIRA, S. C. Outbreak diversity in epidemic waves propagating through distinct geographical scales. **Physical Review Research**, v. 2, n. 4, p. 043306, 2 dez. 2020.

CROSBY, R. et al. **Rural Populations and Health: Determinants, Disparities, and Solutions**. [s.l.] John Wiley & Sons, 2012.

DA COSTA, A. C. C. et al. Spatiotemporal diffusion of influenza A (H1N1): Starting point and risk factors. **PloS One**, v. 13, n. 9, p. e0202832, 2018.

DE ALMEIDA, G. B. et al. Two hundred days of COVID-19 in São Paulo State, Brazil. **Epidemiology and Infection**, v. 148, p. e295, 2 dez. 2020.

DE CAMPOS SILVA, A. R. Health Risks for Poultry Workers in Brazil in the COVID-19 Pandemic. **Bulletin of Latin American Research**, v. 39, n. S1, p. 88–91, 2020.

DE SOUZA, C. D. F.; MACHADO, M. F.; DO CARMO, R. F. Human development, social vulnerability and COVID-19 in Brazil: a study of the social determinants of health. **Infectious Diseases of Poverty**, v. 9, n. 1, p. 124, 31 ago. 2020.

DE SOUZA, W. M. et al. Epidemiological and clinical characteristics of the COVID-19 epidemic in Brazil. **Nature Human Behaviour**, v. 4, n. 8, p. 856–865, ago. 2020.

DEMENECH, L. M. et al. Desigualdade econômica e risco de infecção e morte por COVID-19 no Brasil. **Revista Brasileira de Epidemiologia**, v. 23, p. e200095, 5 out. 2020.

DIAS, J. V. G. **O rigor da morte: a construção simbólica do “animal de açougue” na produção industrial brasileira**. Dissertação (Mestrado em Antropologia Social)—Campinas: Universidade Estadual de Campinas, 2009.

DONAHUE, M. et al. Notes from the Field: Characteristics of Meat Processing Facility Workers with Confirmed SARS-CoV-2 Infection - Nebraska, April-May 2020. **MMWR. Morbidity and mortality weekly report**, v. 69, n. 31, p. 1020–1022, 7 ago. 2020.

DORN, A. VAN; COONEY, R. E.; SABIN, M. L. COVID-19 exacerbating inequalities in the US. **Lancet (London, England)**, v. 395, n. 10232, p. 1243–1244, 2020.

DOS SANTOS, C. H. M. et al. **O que pode dar errado quando se usam os microdados da RAIS para análises do emprego público por ente federado? Um inventário dos problemas conhecidos e algumas soluções**: Mercado de trabalho. São Paulo: DIMAC - IPEA, 2018. Disponível em: http://repositorio.ipea.gov.br/bitstream/11058/9885/1/bmt_65_03_notal_o_que_pode.pdf. Acesso em: 10 maio. 2021.

DYAL, J. W. COVID-19 Among Workers in Meat and Poultry Processing Facilities — 19 States, April 2020. **MMWR. Morbidity and Mortality Weekly Report**, v. 69, 2020.

FARMER, P. Social inequalities and emerging infectious diseases. **Emerging Infectious Diseases**, v. 2, n. 4, p. 259–269, 1996.

FERIGATO, S. et al. The Brazilian Government’s mistakes in responding to the COVID-19 pandemic. **The Lancet**, v. 396, n. 10263, p. 1636, 21 nov. 2020.

FORTALEZA, C. M. C. B. et al. Elementary spatial structures and dispersion of COVID-19: health geography directing responses to public health emergency in São Paulo State, Brazil. **medRxiv**, p. 2020.04.26.20080895, 1 maio 2020a.

FORTALEZA, C. M. C. B. et al. Taking the inner route: spatial and demographic factors affecting vulnerability to COVID-19 among 604 cities from inner São Paulo State, Brazil. **Epidemiology and Infection**, v. 148, p. e118, 19 jun. 2020b.

FRANCO-VILLORIA, M.; VENTRUCCI, M.; RUE, H. A unified view on Bayesian varying coefficient models. **arXiv:1806.02084 [stat]**, 4 dez. 2019.

FRENCH NATIONAL ACADEMY OF MEDICINE. Slaughterhouses: A major target for COVID-19 prevention. **Bulletin De l'Academie Nationale De Medecine**, v. 204, n. 9, p. e109–e110, dez. 2020.

GAMLIN, J. et al. Centring a critical medical anthropology of COVID-19 in global health discourse. **BMJ Global Health**, v. 6, n. 6, p. e006132, jun. 2021.

GAYNOR, T. S.; WILSON, M. E. Social Vulnerability and Equity: The Disproportionate Impact of COVID-19. **Public Administration Review**, v. 80, n. 5, p. 832–838, 2020.

GEITENS, J. F. Os senhores do boi não entraram em quarentena. **o Joio e o Trigo**, 3 set. 2020.

GELMAN, A. et al. **Bayesian data analysis**. 3. ed. Boca Raton: CRC Press, 2014.

GEMELLI, D. D.; CARVALHAL, M. D. Mobilidade Territorial do Trabalho e Formação do Trabalhador para o Capital: o Frigorífico de Aves da Copagril de Marechal Cândido Rondon/PR. **REVISTA PERCURSO**, v. 3, n. 1, p. 39–61, 21 jun. 2011.

GOLLAC, M. L'intensité du travail. **Revue economique**, v. 56, n. 2, p. 195–216, 2005.

GOMES, M. F. DA C. **Nota técnica: SRAG como alerta para epidemias de doenças respiratórias virais**, [s.d.]. Disponível em: <https://portal.fiocruz.br/sites/portal.fiocruz.br/files/documentos/srag_e_a_vigilancia_de_doenças_respiratorias_virais.pdf>. Acesso em: 14 maio. 2021

GÓMEZ-RUBIO, V. **Bayesian inference with INLA**. Boca Raton, FL: Chapman & Hall/CRC Press, 2020.

GOVERNO DO ESTADO DE SÃO PAULO. **Plano SP**. Disponível em: <<https://www.saopaulo.sp.gov.br/planosp/>>. Acesso em: 9 nov. 2021.

GRANADA, D. et al. Saúde e migrações: a pandemia de Covid-19 e os trabalhadores imigrantes nos frigoríficos do Sul do Brasil. **Horizontes Antropológicos**, v. 27, p. 207–226, 3 maio 2021.

GUENTHER, T. et al. Investigation of a superspreading event preceding the largest meat processing plant-related SARS-Coronavirus 2 outbreak in Germany. **SSRN Electronic Journal**, 2020.

GUILLAND, R. et al. Prevalência de transtorno mental e comportamental em trabalhadores de indústrias de abate de suínos e aves no sul do Brasil. **Revista Colombiana de Psicologia**, v. 26, n. 1, p. 163–177, jun. 2017.

HAWRYLUK, I. et al. Inference of COVID-19 epidemiological distributions from Brazilian hospital data. **Journal of The Royal Society Interface**, v. 17, n. 172, p. 20200596, 25 nov. 2020.

HECK, F. M. et al. Os territórios da degradação do trabalho na região sul e o arranjo organizado a partir da COVID-19: A centralidade dos frigoríficos na difusão espacial da doença. **Metodologias e Aprendizado**, v. 3, p. 54–68, 20 jun. 2020.

HENRIQUES, C. M. P.; VASCONCELOS, W. Crises dentro da crise: respostas, incertezas e desencontros no combate à pandemia da Covid-19 no Brasil. **Estudos Avançados**, v. 34, p. 25–44, 10 jul. 2020.

IBGE. **Classificação Nacional de Atividades Econômicas 2.2**. Disponível em: <<https://concla.ibge.gov.br/classificacoes/por-tema/atividades-economicas/subclasses-da-cnae-2-2.html>>. Acesso em: 23 nov. 2020.

IBGE. **Classificação e Caracterização dos Espaços Rurais e Urbanos do Brasil | Uma primeira aproximação**. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/15790-classificacao-e-caracterizacao-dos-espacos-rurais-e-urbanos-do-brasil.html?=&t=o-que-e>>. Acesso em: 15 abr. 2021.

IBGE. **Estimativas da população residente nos municípios brasileiros**. Disponível em: <https://ftp.ibge.gov.br/Estimativas_de_Populacao/Estimativas_2018/estimativa_dou_2018_2_0181019.pdf>. Acesso em: 16 ago. 2021a.

IBGE. **Regiões de Influência das Cidades - REGIC**. Disponível em: <<https://www.ibge.gov.br/geociencias/cartas-e-mapas/redes-geograficas/15798-regioes-de-influencia-das-cidades.html?=&t=o-que-e>>. Acesso em: 4 maio. 2021b.

IBGE. **São Paulo (SP)**. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/sp/sao-paulo.html?>>. Acesso em: 6 maio. 2021.

IBGE. **Preços e custos**. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/precos-e-custos.html>>. Acesso em: 27 dez. 2021.

IKEDO, F.; RUIZ, R. C. (EDS.). **Trabalhar e adoecer na agroindústria: da reabilitação profissional à construção da Norma Regulamentadora dos Frigoríficos (NR 36)**. Florianópolis, SC: Editora Insular, 2014.

INFOGRIPE. **Situação da Gripe**. Disponível em: <<http://info.gripe.fiocruz.br/>>. Acesso em: 12 mar. 2021a.

INFOGRIPE. **Boletim InfoGripe - Semana Epidemiológica (SE) 17 2021**. Rio de Janeiro: [s.n.]. Disponível em: <<https://gitlab.procc.fiocruz.br/mave/repo/-/tree/master/Boletins%20do%20InfoGripe>>. Acesso em: 9 maio. 2020b.

IPEA. **Atlas da vulnerabilidade social nos municípios brasileiros**. Brasília: Ipea, 2015.

ISMAIL, S. J. et al. Navigating inequities: a roadmap out of the pandemic. **BMJ Global Health**, v. 6, n. 1, p. e004087, 1 jan. 2021.

JAKOBI, H. R. et al. Benefícios auxílio-doença concedidos aos trabalhadores empregados no ramo de carne e pescado no Brasil em 2008. **Cadernos de Saúde Pública**, v. 31, p. 194–207, jan. 2015.

- JALILIAN, A.; MATEU, J. A hierarchical spatio-temporal model to analyze relative risk variations of COVID-19: a focus on Spain, Italy and Germany. **Stochastic Environmental Research and Risk Assessment: Research Journal**, p. 1–16, 23 mar. 2021.
- JAYA, I. G. N. M.; FOLMER, H. Bayesian Spatiotemporal Forecasting and Mapping of COVID-19 Risk with Application to West Java Province, Indonesia. **Journal of Regional Science**, v. n/a, n. n/a, 2020.
- JENKS, G. F. The data model concept in statistical mapping. **International yearbook of cartography**, v. 7, p. 186–190, 1967.
- JOHNSON, D. P.; RAVI, N.; BRANEON, C. V. Spatiotemporal Associations Between Social Vulnerability, Environmental Measurements, and COVID-19 in the Conterminous United States. **GeoHealth**, v. 5, n. 8, p. e2021GH000423, 2021.
- KANG, S. Y. et al. Spatio-temporal mapping of Madagascar's Malaria Indicator Survey results to assess Plasmodium falciparum endemicity trends between 2011 and 2016. **BMC Medicine**, v. 16, n. 1, p. 71, Maio 2018.
- KARAYE, I. M.; HORNEY, J. A. The Impact of Social Vulnerability on COVID-19 in the U.S.: An Analysis of Spatially Varying Relationships. **American Journal of Preventive Medicine**, v. 59, n. 3, p. 317–325, 1 set. 2020.
- 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. 2020.
- KHAZANCHI, R. et al. County-Level Association of Social Vulnerability with COVID-19 Cases and Deaths in the USA. **Journal of General Internal Medicine**, v. 35, n. 9, p. 2784–2787, 1 set. 2020.
- KNORR-HELD, L. Bayesian modelling of inseparable space-time variation in disease risk. **Statistics in Medicine**, v. 19, n. 17–18, p. 2555–2567, 2000.
- LAWSON, A. **Disease mapping and risk assessment for public health**. Chichester; New York: Wiley, 1999.
- LAWSON, A. **Bayesian disease mapping: hierarchical modeling in spatial epidemiology**. 2nd ed ed. Boca Raton: Taylor & Francis, 2013a.
- LAWSON, A. Disease Map Reconstruction and Relative Risk Estimation. In: **Bayesian disease mapping: hierarchical modeling in spatial epidemiology**. Chapman & Hall/CRC interdisciplinary statistics series. 2nd ed ed. Boca Raton: Taylor & Francis, 2013b. p. 84–86.
- LAWSON, A. et al. Integration of Different Epidemiologic Perspectives and Applications to Spatial Epidemiology. In: **Handbook of spatial epidemiology**. Boca Raton: CRC Press, 2016. p. 3–38.
- LEE, E.; BANSAL, S. Socio-environmental and measurement factors drive variation in influenza-like illness. **Online Journal of Public Health Informatics**, v. 9, n. 1, 2 maio 2017.

LI, S. L. et al. Higher risk of death from COVID-19 in low-income and non-White populations of São Paulo, Brazil. **BMJ Global Health**, v. 6, n. 4, p. e004959, 1 abr. 2021.

LÓPEZ-QUÍLEZ, A. Spatio-Temporal Analysis of Infectious Diseases. **International Journal of Environmental Research and Public Health**, v. 16, n. 4, p. 669, jan. 2019.

LORENZ, C. et al. Examining socio-economic factors to understand the hospital case fatality rates of COVID-19 in the city of São Paulo, Brazil. **Transactions of the Royal Society of Tropical Medicine and Hygiene**, p. trab144, 22 set. 2021.

MACHADO, L. DE F.; MUROFUSE, N. T.; MARTINS, J. T. Vivências de ser trabalhador na agroindústria avícola dos usuários da atenção à saúde mental. **Saúde em Debate**, v. 40, p. 134–147, set. 2016.

MAENO, M. COVID-19 como uma doença relacionada ao trabalho. **Revista Brasileira de Saúde Ocupacional**, v. 46, 13 dez. 2021.

MAESTRIPIERI, L. The Covid-19 Pandemics: why Intersectionality Matters. **Frontiers in Sociology**, v. 6, p. 52, 2021.

MARRA, G. C. **Saúde e processo de trabalho em frigoríficos: da necessidade ao adoecimento**. Tese (Doutorado em Saúde Pública)—Rio de Janeiro: Fundação Oswaldo Cruz, 2019.

MARTÍNEZ-BELLO, D.; LÓPEZ-QUÍLEZ, A.; PRIETO, A. T. Spatiotemporal modeling of relative risk of dengue disease in Colombia. **Stochastic Environmental Research and Risk Assessment**, v. 32, n. 6, p. 1587–1601, 1 jun. 2018.

MARTINO, S.; RUE, H. **Implementing approximate bayesian inference using integrated nested laplace approximation: a manual for the inla program**. [s.l: s.n.]. Disponível em: <<http://www.math.ntnu.no/hrue/GMRFsim/manual.pdf>>.

MATTA, G. C. et al. (EDS.). **Os impactos sociais da Covid-19 no Brasil: populações vulnerabilizadas e respostas à pandemia**. Rio de Janeiro: Série Informação para ação na Covid-19 | Fiocruz, 2021.

MEIRELLES, L. C. **66 anos ENSP: Saúde dos trabalhadores e trabalhadoras de frigoríficos em tempos de Covid-19: 66 anos ENSP**. Rio de Janeiro, 16 set. 2020. Disponível em: <<https://portal.fiocruz.br/video/66-anos-ensp-saude-dos-trabalhadores-e-trabalhadoras-de-frigorificos-em-tempos-de-covid-19>>. Acesso em: 16 abr. 2021

MELIKER, J. R.; SLOAN, C. D. Spatio-temporal epidemiology: principles and opportunities. **Spatial and Spatio-Temporal Epidemiology**, v. 2, n. 1, p. 1–9, mar. 2011.

MELLOR, K. C. et al. Comparative Epidemiology of Highly Pathogenic Avian Influenza Virus H5N1 and H5N6 in Vietnamese Live Bird Markets: Spatiotemporal Patterns of Distribution and Risk Factors. **Frontiers in Veterinary Science**, v. 5, p. 51, 2018.

MIDDLETON, J.; REINTJES, R.; LOPES, H. Meat plants-a new front line in the covid-19 pandemic. **BMJ (Clinical research ed.)**, v. 370, p. m2716, 9 jul. 2020.

MINISTÉRIO DA SAÚDE. **Ficha de registro individual: casos de síndrome respiratória aguda grave hospitalizado.** Disponível em: <<https://saude.rs.gov.br/upload/arquivos/carga20190433/05143355-25141516-1-ficha-srag-hospital.pdf>>. Acesso em: 8 out. 2020.

MINISTÉRIO DO TRABALHO. **O que é RAIS?** Disponível em: <<http://pdet.mte.gov.br/o-que-e-rais>>. Acesso em: 10 maio. 2021.

MINISTÉRIO DO TRABALHO. **Observatório de Segurança e Saúde no Trabalho.** Disponível em: <<https://smartlabbr.org>>. Acesso em: 27 dez. 2021.

MINISTÉRIO DO TRABALHO E EMPREGO. **Nota técnica.** Brasília: MTE, 2004.

MODENESE, A. et al. Frequency of Anti-SARS-CoV-2 Antibodies in Various Occupational Sectors in an Industrialized Area of Northern Italy from May to October 2020. **International Journal of Environmental Research and Public Health**, v. 18, n. 15, p. 7948, 27 jul. 2021.

MORRIS, M. et al. Bayesian hierarchical spatial models: Implementing the Besag York Mollié model in stan. **Spatial and Spatio-temporal Epidemiology**, v. 31, p. 100301, 1 nov. 2019.

MUSENGE, E. et al. Bayesian analysis of zero inflated spatiotemporal HIV/TB child mortality data through the INLA and SPDE approaches: Applied to data observed between 1992 and 2010 in rural North East South Africa. **International journal of applied earth observation and geoinformation: ITC journal**, v. 22, n. 100, p. 86–98, jun. 2013.

NAKADA, L. Y. K.; URBAN, R. C. COVID-19 pandemic: environmental and social factors influencing the spread of SARS-CoV-2 in São Paulo, Brazil. **Environmental Science and Pollution Research International**, v. 28, n. 30, p. 40322–40328, ago. 2021.

NASCIMENTO, C. **‘Exemplo de tratamento precoce’, Porto Feliz teve alta de mortes por Covid.** Disponível em: <<https://veja.abril.com.br/coluna/maquiavel/exemplo-de-tratamento-precoce-porto-feliz-teve-alta-de-mortes-por-covid/>>. Acesso em: 27 dez. 2021.

NASCIMENTO, E.; TOMBINI, L. H. T.; RIPPLINGER, F. Espacialização da Covid-19 no Sul do Brasil: a interiorização da doença e o caso da Mesorregião Grande Fronteira do MERCOSUL. **Finisterra**, v. 55, n. 115, p. 27–35, 11 nov. 2020.

NAYAK, A. et al. **Impact of Social Vulnerability on COVID-19 Incidence and Outcomes in the United States.** [s.l.] Public and Global Health, 14 abr. 2020. Disponível em: <<http://medrxiv.org/lookup/doi/10.1101/2020.04.10.20060962>>. Acesso em: 23 dez. 2021.

NEELON, B. et al. Spatial and temporal trends in social vulnerability and COVID-19 incidence and death rates in the United States. **PloS One**, v. 16, n. 3, p. e0248702, 2021.

NEVES, M. F. Mapeamento e quantificação da cadeia de carne bovina em 2010. In: **Estratégias para a Carne Bovina no Brasil.** São Paulo: Atlas, 2012.

NIQUINI, R. P. et al. SRAG por COVID-19 no Brasil: descrição e comparação de características demográficas e comorbidades com SRAG por influenza e com a população geral. **Cadernos de Saúde Pública**, v. 36, n. 7, p. e00149420, 2020.

NOBRE, A. A.; SCHMIDT, A. M.; LOPES, H. F. Spatio-temporal models for mapping the incidence of malaria in Pará. **Environmetrics**, v. 16, n. 3, p. 291–304, 2005.

NOOR, A. M. et al. The changing risk of *Plasmodium falciparum* malaria infection in Africa: 2000-10: a spatial and temporal analysis of transmission intensity. **Lancet (London, England)**, v. 383, n. 9930, p. 1739–1747, 17 maio 2014.

NUNES, H. G. L. Por que não devemos chamar o coronavírus de democrático. **Nexo Jornal**, 2020.

OBSERVATÓRIO COVID-19 BR. **Observatório Covid-19 BR**. Disponível em: <<https://covid19br.github.io>>. Acesso em: 12 mar. 2021.

OLIVEIRA, R. G. DE et al. Desigualdades raciais e a morte como horizonte: considerações sobre a COVID-19 e o racismo estrutural. **Cadernos de Saúde Pública**, v. 36, 18 set. 2020.

On Revolution. Excerpts of a conversation between Grace Lee Boggs and Angela Davis at University of California, Berkeley in 2012. : Empowering Women of Color Conference, ‘A Holistic Approach: Justice, Access and Healing’. Berkeley, 2012. Disponível em: <<https://www.youtube.com/watch?v=h9IsJwE0B1c>>. Acesso em: 6 ago. 2021

ORGANIZAÇÃO MUNDIAL DA SAÚDE. **Coronavirus disease 2019 (COVID-19) - Situation Report 51**: Organização Mundial da Saúde. Geneva: OMS, 11 abr. 2020. Disponível em: <<https://apps.who.int/iris/bitstream/handle/10665/331780/nCoVsitrep11Apr2020-eng.pdf>>. Acesso em: 14 abr. 2021.

OROSZI, B. et al. Unequal burden of COVID-19 in Hungary: a geographical and socioeconomic analysis of the second wave of the pandemic. **BMJ Global Health**, v. 6, n. 9, p. e006427, 9 set. 2021.

PACHECO, J. W. F.; YAMANAKA, H. T. **Guia técnico ambiental de abates (bovino e suíno)**: P+L. São Paulo: CETESB, 2006. Disponível em: <<https://cetesb.sp.gov.br/consumosustentavel/wp-content/uploads/sites/20/2013/11/abate.pdf>>. Acesso em: 10 jan. 2022.

PAIXÃO, B. et al. Estimation of COVID-19 Under-Reporting in the Brazilian States Through SARI. **New Generation Computing**, p. 1–23, 14 mar. 2021.

PAUL, R. et al. Progression of COVID-19 From Urban to Rural Areas in the United States: A Spatiotemporal Analysis of Prevalence Rates. **The Journal of Rural Health**, v. 36, n. 4, p. 591–601, 2020.

PAUL, R. et al. Dynamics of Covid-19 mortality and social determinants of health: a spatiotemporal analysis of exceedance probabilities. **Annals of Epidemiology**, v. 62, p. 51–58, out. 2021.

PEBESMA, E. J. Simple features for R: standardized support for spatial vector data. **R J.**, v. 10, n. 1, p. 439, 2018.

PENSSAN. **VIGISAN. Inquérito Nacional sobre Insegurança Alimentar no Contexto da Pandemia de Covid-19 no Brasil**. [s.l.: s.n.]. Disponível em: <http://olheparaafome.com.br/VIGISAN_Inseguranca_alimentar.pdf>. Acesso em: 27 dez. 2021.

PEREIRA, A. K.; OLIVEIRA, M. S.; SAMPAIO, T. DA S. Heterogeneidades das políticas estaduais de distanciamento social diante da COVID-19: aspectos políticos e técnico-administrativos. **Revista de Administração Pública**, v. 54, p. 678–696, 28 ago. 2020.

PEREIRA, R. H. M.; GONÇALVES, C. N. **geobr: Loads Shapefiles of Official Spatial Data Sets of Brazil**. Disponível em: <<https://github.com/ipeaGIT/geobr>>. Acesso em: 5 jun. 2021.

PERES, I. T. et al. Sociodemographic factors associated with COVID-19 in-hospital mortality in Brazil. **Public Health**, v. 192, p. 15–20, mar. 2021.

PINA, R. Como frigoríficos propagaram o coronavírus em pequenas cidades do país. **Pública**, p. 14, 2020.

PORTELA, M. C. et al. **Limites e possibilidades dos municípios brasileiros para o enfrentamento dos casos graves de COVID19**. Rio de Janeiro: Escola Nacional de Saúde Pública Sergio Arouca, 2020. Disponível em: <<https://www.arca.fiocruz.br/handle/icict/40749>>. Acesso em: 23 dez. 2021.

QUININO, L. R. DE M. et al. [Spatial and temporal aspects and factors associated with the spread of Covid-19 to the interior of the State of Pernambuco, Brazil]. **Ciencia & Saude Coletiva**, v. 26, n. 6, p. 2171–2182, jun. 2021.

QUINN, S. C.; KUMAR, S. Health inequalities and infectious disease epidemics: a challenge for global health security. **Biosecurity and Bioterrorism: Biodefense Strategy, Practice, and Science**, v. 12, n. 5, p. 263–273, out. 2014.

R DEVELOPMENT CORE TEAM. **a language and environment for statistical computing: reference index**. Vienna: R Foundation for Statistical Computing, 2010.

RANZANI, O. T. et al. Characterisation of the first 250,000 hospital admissions for COVID-19 in Brazil: a retrospective analysis of nationwide data. **The Lancet. Respiratory Medicine**, v. 9, n. 4, p. 407–418, abr. 2021.

REDE TVT. **Trabalhadores em frigoríficos realizam manifestação por condições de trabalho**. São Paulo, 24 set. 2020. Disponível em: <<https://www.youtube.com/watch?v=32dxNQl4ejE>>. Acesso em: 27 ago. 2021

Retratos da fome no Brasil. **Outras Palavras**, 2021.

REZENDE, L. F. M. et al. Adults at high-risk of severe coronavirus disease-2019 (Covid-19) in Brazil. **Revista de Saúde Pública**, v. 54, p. 50–50, 18 jun. 2020.

RIBEIRO, H. V. et al. City size and the spreading of COVID-19 in Brazil. **PLOS ONE**, v. 15, n. 9, p. e0239699, 23 set. 2020.

RIBEIRO, K. B. et al. Social inequalities and COVID-19 mortality in the city of São Paulo, Brazil. **International Journal of Epidemiology**, 28 fev. 2021.

RICHARDSON, S. et al. Interpreting Posterior Relative Risk Estimates in Disease-Mapping Studies. **Environmental Health Perspectives**, v. 112, n. 9, p. 1016–1025, jun. 2004.

- RIEBLER, A. et al. An intuitive Bayesian spatial model for disease mapping that accounts for scaling. **Statistical Methods in Medical Research**, v. 25, n. 4, p. 1145–1165, Agosto 2016.
- RIVERA ARIZA, S. et al. [COVID-19 outbreaks in occupational settings in Spain, one year of follow-up (June 2020-June 2021)]. **Revista Espanola De Salud Publica**, v. 95, p. e202110180, 22 out. 2021.
- RUE, H. et al. Bayesian Computing with INLA: A Review. **Annual Review of Statistics and Its Application**, v. 4, n. 1, p. 395–421, 7 mar. 2017.
- RUE, H.; HELD, L. **Gaussian Markov random fields: theory and applications**. Boca Raton: Chapman & Hall/CRC, 2005.
- RUE, H.; MARTINO, S.; CHOPIN, N. Approximate Bayesian inference for latent Gaussian models by using integrated nested Laplace approximations. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, v. 71, n. 2, p. 319–392, 2009.
- SABINO, E. C. et al. Resurgence of COVID-19 in Manaus, Brazil, despite high seroprevalence. **The Lancet**, v. 397, n. 10273, p. 452–455, 6 fev. 2021.
- SAHU, S. K.; BÖHNING, D. Bayesian spatio-temporal joint disease mapping of Covid-19 cases and deaths in local authorities of England. **Spatial Statistics**, p. 100519, 12 maio 2021.
- SCHNEIDER, I. J. C. et al. Incidência e mortalidade por COVID-19 nos municípios de Santa Catarina: associação com indicadores sociodemográficos. **Research, Society and Development**, v. 9, n. 10, p. e7719109208–e7719109208, 18 out. 2020.
- SEADE. **SP Contra o Novo Coronavírus. Boletim Completo**. Disponível em: <<https://www.seade.gov.br/coronavirus/>>. Acesso em: 10 maio. 2021.
- SEGATA, J. et al. A Covid-19, a Indústria da Carne e Outras Doenças do Capitalismo. In: MATTA, G. C.; REGO, S.; SOUTO, E. P. (Eds.). **Os impactos sociais da Covid-19 no Brasil: populações vulnerabilizadas e respostas à pandemia**. Rio de Janeiro: Série Informação para ação na Covid-19 | Fiocruz, 2021a. p. 73–85.
- SEGATA, J. et al. A Covid-19 e suas múltiplas pandemias. **Horizontes Antropológicos**, v. 27, p. 7–25, 3 maio 2021b.
- SERRA, H. R. H.; OLIVEIRA, V. DA S. Circulação espacial da Covid-19 através dos frigoríficos no Sul e no Sudeste do Pará: impactos espaciais de uma “atividade essencial” em meio à pandemia. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 16, n. 4, 15 dez. 2020.
- SILVA, S. J. R. DA; PENA, L. Collapse of the public health system and the emergence of new variants during the second wave of the COVID-19 pandemic in Brazil. **One Health**, v. 13, p. 100287, 1 dez. 2021.
- SILVEIRA, A. L. DA; MERLO, Á. R. C. Superexploração e o processo de adoecimento pelo trabalho na indústria frigorífica de Chapecó/SC. **Revista Grifos**, v. 26, n. 43, p. 254–286, 2017.

SILVEIRA, R. L. L. et al. Observando a dispersão territorial da Covid-19 na região dos vales e nas cidades médias de Santa Cruz do Sul e Lajeado-RS. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 16, n. 4, 15 dez. 2020.

SIMPSON, D. et al. Penalising Model Component Complexity: A Principled, Practical Approach to Constructing Priors. **Statistical Science**, v. 32, n. 1, 1 fev. 2017.

SLAVOV, S. N. et al. Genomic monitoring unveil the early detection of the SARS-CoV-2 B.1.351 (beta) variant (20H/501Y.V2) in Brazil. **Journal of Medical Virology**, v. 93, n. 12, p. 6782–6787, 2021.

SOUZA, M. C. DE; SOUZA, J. N.; MERCES, M. C. DAS. Racismo estrutural como barreira de acesso à saúde: O que a pandemia da COVID-19 nos revela? **Journal of Multiprofessional Health Research**, v. 2, n. 2, p. e02.102-e02.106, 27 maio 2021.

STEINBERG, J. et al. COVID-19 Outbreak Among Employees at a Meat Processing Facility - South Dakota, March-April 2020. **MMWR. Morbidity and mortality weekly report**, v. 69, n. 31, p. 1015–1019, 7 ago. 2020.

STIER, A.; BERMAN, M. G.; BETTENCOURT, L. **COVID-19 Attack Rate Increases with City Size**. Rochester, NY: Social Science Research Network, 30 mar. 2020. Disponível em: <<https://papers.ssrn.com/abstract=3564464>>. Acesso em: 20 dez. 2021.

TAVOLARO, P. et al. Empowerment como forma de prevenção de problemas de saúde em trabalhadores de abatedouros. **Revista de Saúde Pública**, v. 41, p. 307–312, abr. 2007.

TESS, B. H. et al. Assessment of initial SARS-CoV-2 seroprevalence in the most affected districts in the municipality of São Paulo, Brazil. **The Brazilian Journal of Infectious Diseases: An Official Publication of the Brazilian Society of Infectious Diseases**, v. 25, n. 4, p. 101604, ago. 2021.

TOOGE, R. **Ministério Público do Trabalho investiga controle da Covid-19 entre funcionários de 61 frigoríficos em 11 estados**. Disponível em: <<https://g1.globo.com/economia/agronegocios/noticia/2020/05/08/ministerio-publico-do-trabalho-investiga-controle-da-covid-19-entre-funcionarios-de-61-frigorificos-em-11-estados.ghtml>>. Acesso em: 28 abr. 2021.

TRICCO, A. C. et al. Impact of H1N1 on socially disadvantaged populations: systematic review. **PloS One**, v. 7, n. 6, p. e39437, 2012.

VASCONCELLOS, M. DE C.; PIGNATTI, M. G.; PIGNATI, W. A. Emprego e acidentes de trabalho na indústria frigorífica em áreas de expansão do agronegócio, Mato Grosso, Brasil. **Saúde e Sociedade**, v. 18, p. 662–672, dez. 2009.

WAKEFIELD, J. Ecologic Studies Revisited. **Annual Review of Public Health**, v. 29, n. 1, p. 75–90, 2008.

WAKEFIELD, J.; SMITH, T. R. Ecological Modeling: General Issues. In: LAWSON, A. et al. (Eds.). **Handbook of spatial epidemiology**. Boca Raton: CRC Press, 2016. p. 99–113.

WALLER, L. A.; GOTWAY, C. A. Visualizing Spatial Data. In: **Applied spatial statistics for public health data**. Wiley series in probability and statistics. Hoboken, N.J: John Wiley & Sons, 2004. p. 68–117.

WALTENBURG, M. A. Update: COVID-19 Among Workers in Meat and Poultry Processing Facilities — United States, April–May 2020. **MMWR. Morbidity and Mortality Weekly Report**, v. 69, 2020.

WANG, C. et al. The spatial association of social vulnerability with COVID-19 prevalence in the contiguous United States. **International Journal of Environmental Health Research**, v. 0, n. 0, p. 1–8, 23 nov. 2020.

WHITTLE, R. S.; DIAZ-ARTILES, A. An ecological study of socioeconomic predictors in detection of COVID-19 cases across neighborhoods in New York City. **BMC medicine**, v. 18, n. 1, p. 271, 4 set. 2020.

WICKHAM, H. ggplot2. **Wiley Interdisciplinary Reviews: Computational Statistics**, v. 3, n. 2, p. 180–185, 2011.

WICKHAM, H. et al. **Dplyr**. useR! Conference. **Anais...**2014.

WICKHAM, H. Package ‘tidyr’. **Easily Tidy Data with ‘spread’ and ‘gather ()’ Functions**, 2017.

WOOLF, S. H.; CHAPMAN, D. A.; LEE, J. H. COVID-19 as the Leading Cause of Death in the United States. **JAMA**, v. 325, n. 2, p. 123–124, 12 jan. 2021.

ZEISER, F. A. et al. **First and Second COVID-19 Waves in Brazil: A Cross-Sectional Study of Patients’ Characteristics Related to In-Hospital Mortality**. Rochester, NY: Social Science Research Network, 27 jul. 2021. Disponível em: <<https://papers.ssrn.com/abstract=3894389>>. Acesso em: 3 out. 2021.

APÊNDICE A – MATERIAL SUPLEMENTAR

Na tabela S1 constam os valores dos índices de Moran globais encontrados e seus respectivos *p*-valores, como etapa inicial da análise exploratória. Os resultados obtidos apontam a existência de autocorrelação espacial para ambos os desfechos – casos e óbitos por SRAG-COVID – mas com valores mais altos no ano de 2020.

Tabela S1: Índices I de Moran para autocorrelação espacial para casos e óbitos por SRAG-COVID, no estado de São Paulo, de março de 2020 a agosto de 2021.

	2020		2021	
	Índice	p-valor	Índice	p-valor
Casos	0,4448	1,04e-73	0,3513	1,02e-46
Óbitos	0,3623	8,2e-50	0,2789	2,95e-30

Fonte dos dados: SIVEP-Gripe.

Quadro S1: Frequência absoluta (n) e relativa (%) das subclasses CNAE 2.0 relativas à atividade frigorífica no estado de São Paulo, em 2020.

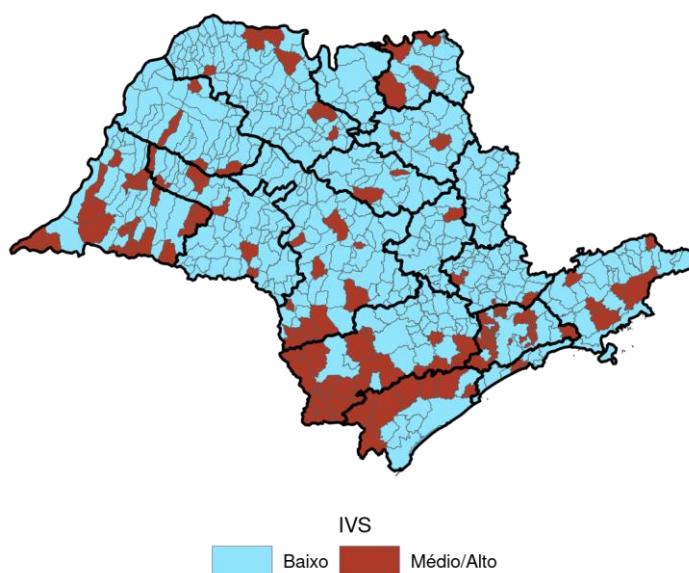
Subclasse CNAE 2.0	Descrição da Atividade Econômica	n (%)
1012101	Abate de Aves	30.852 (54,17%)
1011201	Frigorífico - Abate de Bovinos	22.569 (39,63%)
1012103	Frigorífico - Abate de Suínos	2979 (5,23%)
1011205	Matadouro - Abate de Reses Sob Contrato, Exceto Abate de Suínos	493 (0,86%)
1012102	Abate de Pequenos Animais	39 (0,06%)
1011203	Frigorífico - Abate de Ovinos e Caprinos	16 (< 0,01%)
1011202	Frigorífico - Abate de Eqüinos	1 (< 0,01%)
1011204	Frigorífico - Abate de Bufalinos	0 (0%)
1012104	Matadouro - Abate de Suínos Sob Contrato	0 (0%)

1013901	Fabricação de Produtos de Carne	0 (0%)
1013902	Preparação de Subprodutos do Abate	0 (0%)
Total		56.949 (100%)

Fonte: RAIS, 2020.

A distribuição espacial do Índice de Vulnerabilidade Social (IVS) em sua forma categorizada está ilustrada na Figura S1. Nota-se a concentração de municípios com vulnerabilidade social média/alta no Sul do estado, principalmente nos DRS Sorocaba e Registro.

Figura S1: Distribuição espacial do Índice de Vulnerabilidade Social (IVS) em sua forma categorizada em Baixo e Médio/Alto, no estado de São Paulo.

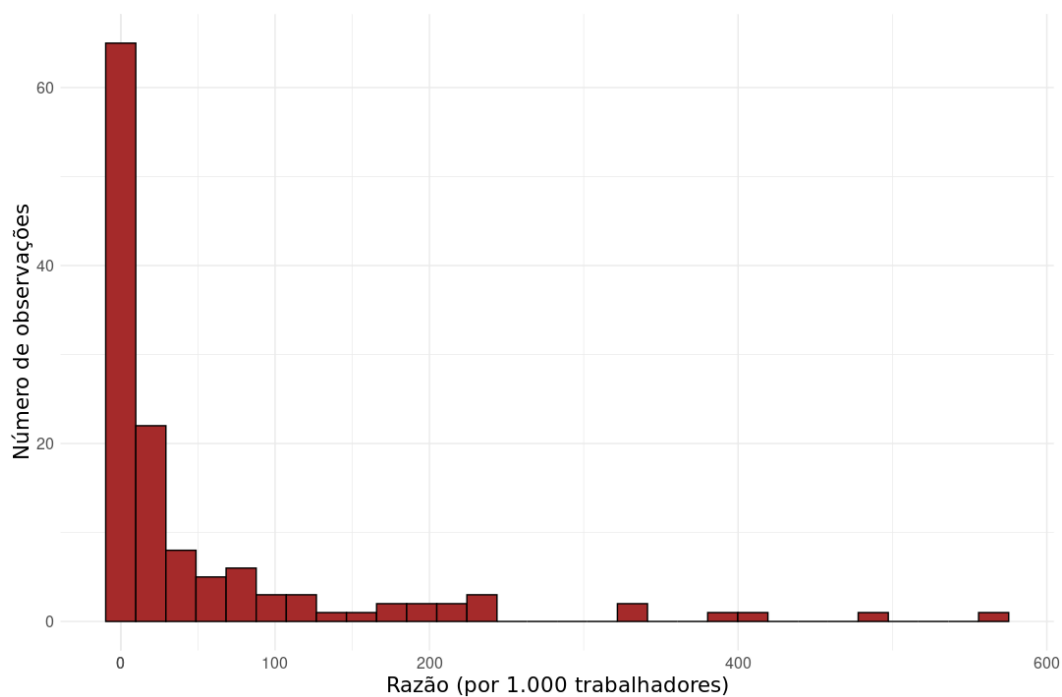


Fonte dos dados: IPEA (2015).

Na Figura S2 está expressa a distribuição da razão de trabalhadores de frigoríficos nos municípios a cada 1.000 trabalhadores registrados na RAIS 2020. Para possibilitar melhor visualização da distribuição, os registros com valor nulo (516 municípios) não foram inclusos no gráfico.

Figura S2: Histograma da razão de trabalhadores de frigoríficos por total de trabalhadores no município, multiplicada por 1.000. Os valores zerados não foram incluídos no gráfico.

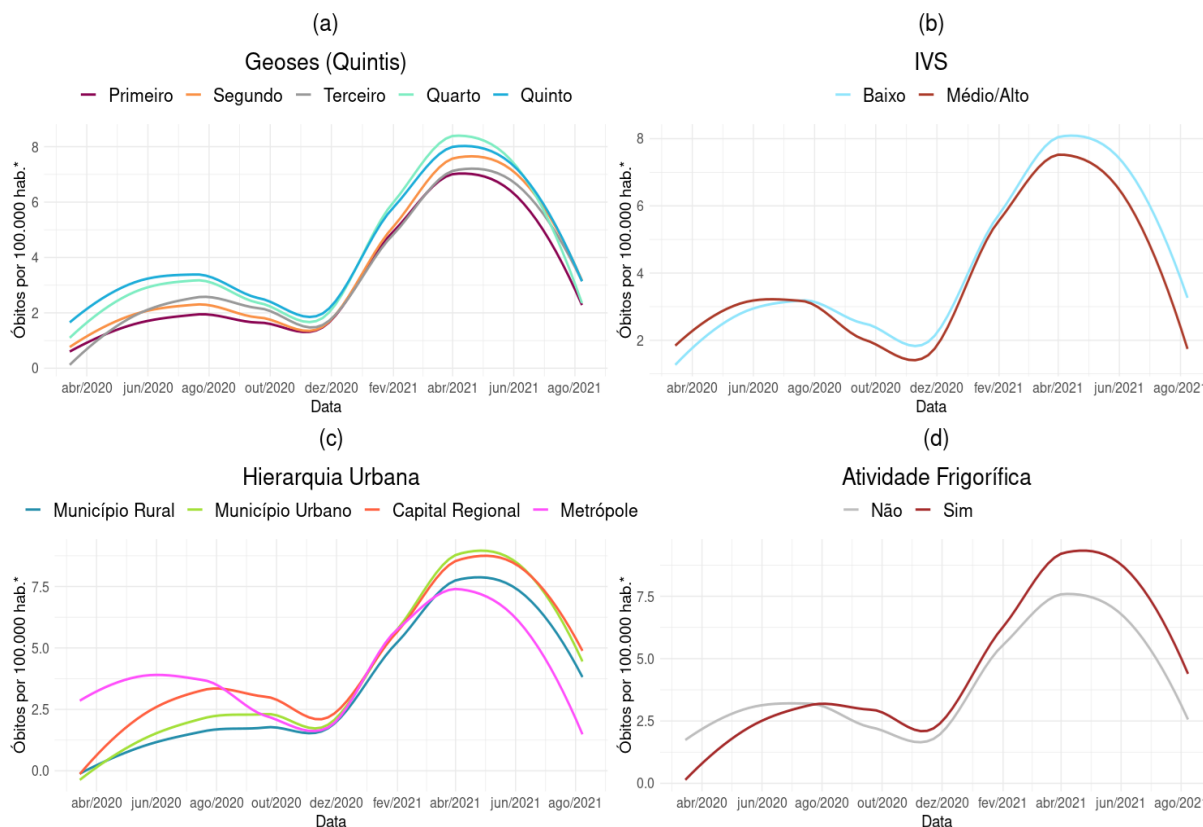
Número de observações zeradas: 516.



Fonte dos Dados: RAIS, 2020.

Na Figura S3, estão representadas as séries semanais de mortalidade por SRAG-COVID agregadas entre as categorias das covariáveis. Os padrões apresentados são similares àqueles observados para as séries de incidência (Figura 7), onde os municípios com maior índice socioeconômico, menor vulnerabilidade social, e maior hierarquia urbana apresentaram maiores taxas. No entanto, para esse desfecho as diferenças entre as categorias foram mais tênues.

Figura S3: Óbitos por SRAG-COVID semanais por 100.000 habitantes suavizados pelo método *loess* por quintis de GeoSES (a), categoria de IVS (b), hierarquia urbana (c) e atividade frigorífica (d).

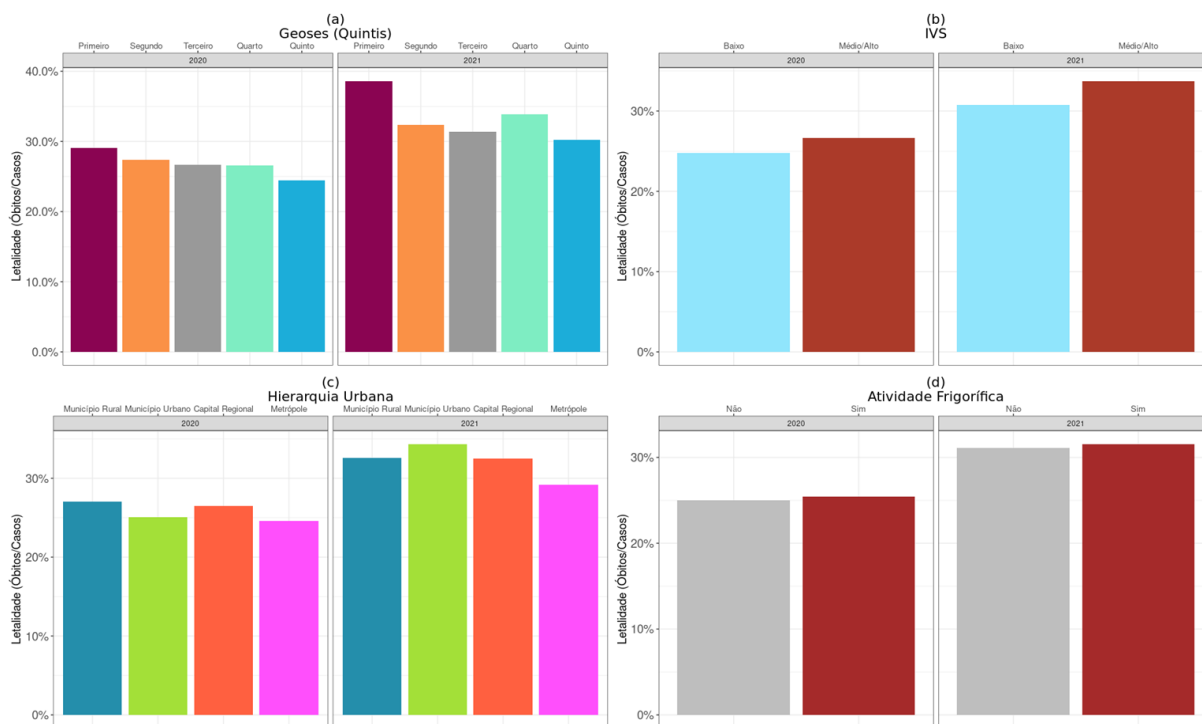


*: Taxa suavizada temporalmente pelo m todo *loess*.

Fonte dos dados: SIVEP-Gripe, Barrozo *et al.* (2020); IPEA (2015); IBGE(2017, 2018b); Programa de Dissemina o das Estat sticas do Trabalho (PDET).

Embora n o seja um dos desfechos abordados pelo estudo, verificou-se a diferen a da letalidade hospitalar ( bitos por SRAG-COVID no per odo/casos de SRAG-COVID no per odo) entre as categorias das covari veis na Figura S4. Para esse desfecho, foi notada uma invers o em rela o aos padr es observados para incid ncia e mortalidade, onde agora os munic pios com menor  ndice socioecon mico, maior vulnerabilidade social e menor hierarquia urbana foram mais afetados, o que se assemelha ao observado em outras an lises espa o-temporais que abordaram letalidade (LORENZ *et al.*, 2021; OROSZI *et al.*, 2021).

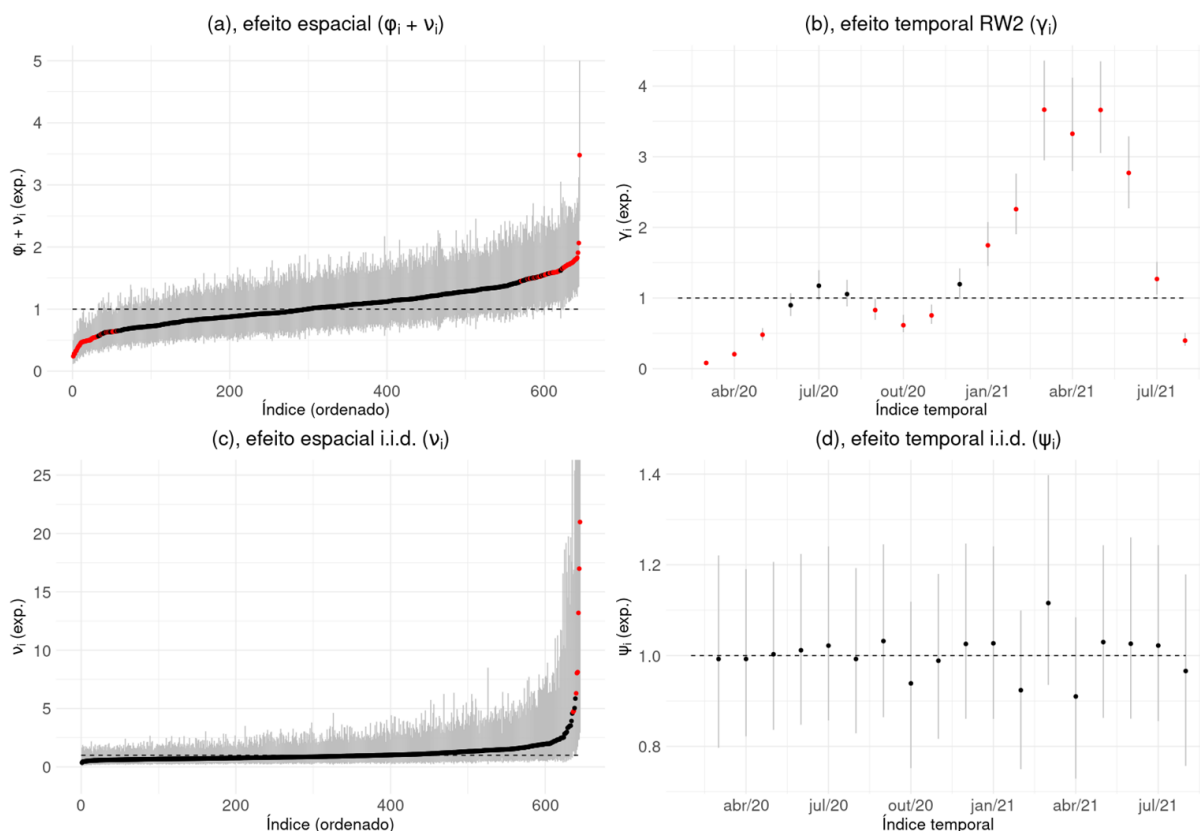
Figura S4: Letalidade hospitalar (HCFR, número de óbitos por SRAG-COVID/número de casos de SRAG-COVID) entre as categorias de GeoSES (a), IVS (b), Hierarquia urbana (c), e Atividade Frigorífica (d) em 2020 e 2021.



Fonte dos dados: SIVEP-Gripe, Barrozo *et al.* (2020); IPEA (2015); IBGE(2017, 2018b); Programa de Disseminação das Estatísticas do Trabalho (PDET).


Tratando de modelagem, a Figura S5 apresenta as estimativas médias e intervalos de credibilidade de 95% para os efeitos aleatórios espaciais e temporais estruturados e não estruturados. A partir desses resultados justifica-se a remoção dos efeitos aleatórios não estruturados do modelo final, visto que estes não contribuíam para a captura de variabilidade dos desfechos – possuíam todas (no caso do efeito temporal) ou a grande maioria (no caso do espacial) as estimativas médias próximas do valor 1 e seus intervalos incluindo o valor 1. Os resultados foram similares para ambos os desfechos.

Figura S5: Médias dos efeitos aleatórios espaciais conjuntos (a) e não estruturado (c) em cada município e temporais estruturado (b) e não estruturado (d) em cada mês, no modelo para casos de SRAG-COVID. Linhas em cinza representam o intervalo de credibilidade de 95%, e as observações na cor vermelha indicam que tal intervalo não inclui o valor 1.



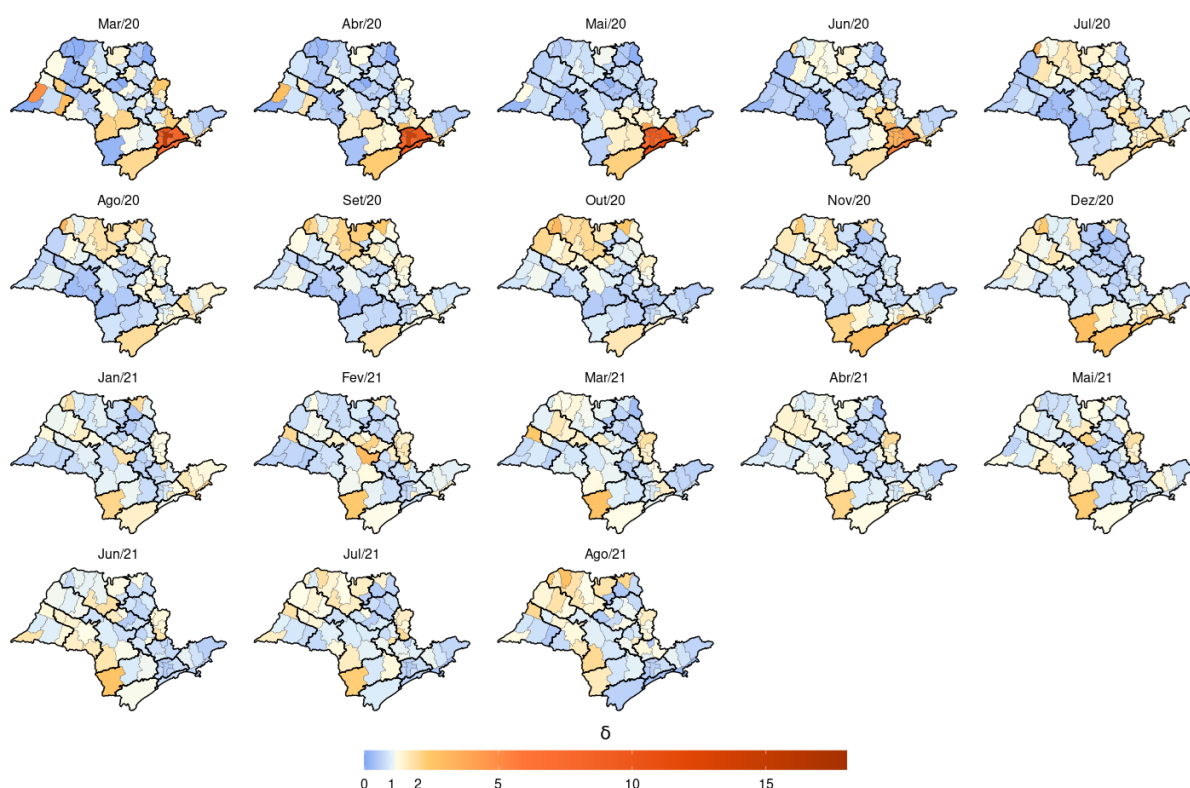
Ao testar a possibilidade da variação dos coeficientes das covariáveis ao longo do tempo, a variável GeoSES foi a única que apresentou coeficientes cujos intervalos de credibilidade não incluíam o valor 1 em pelo menos algum dos períodos. A variação dessas estimativas (média e intervalo) se encontram na Figura S6. A diferença mais evidente se dá no mês de início do estudo, março de 2020, onde o coeficiente assume seu maior valor médio. Após esse mês, no entanto, as estimativas se mostram similares, e sem nenhum padrão temporal claro. Dessa forma, optou-se por manter o coeficiente fixo no tempo para maior parcimônia do modelo.

Figura S6: Estimativas da média e intervalos de credibilidade de 95% para o coeficiente relativo ao índice GeoSES variando no tempo sem estrutura de correlação (i.i.d.) para o modelo estatístico para casos de SRAG-COVID.



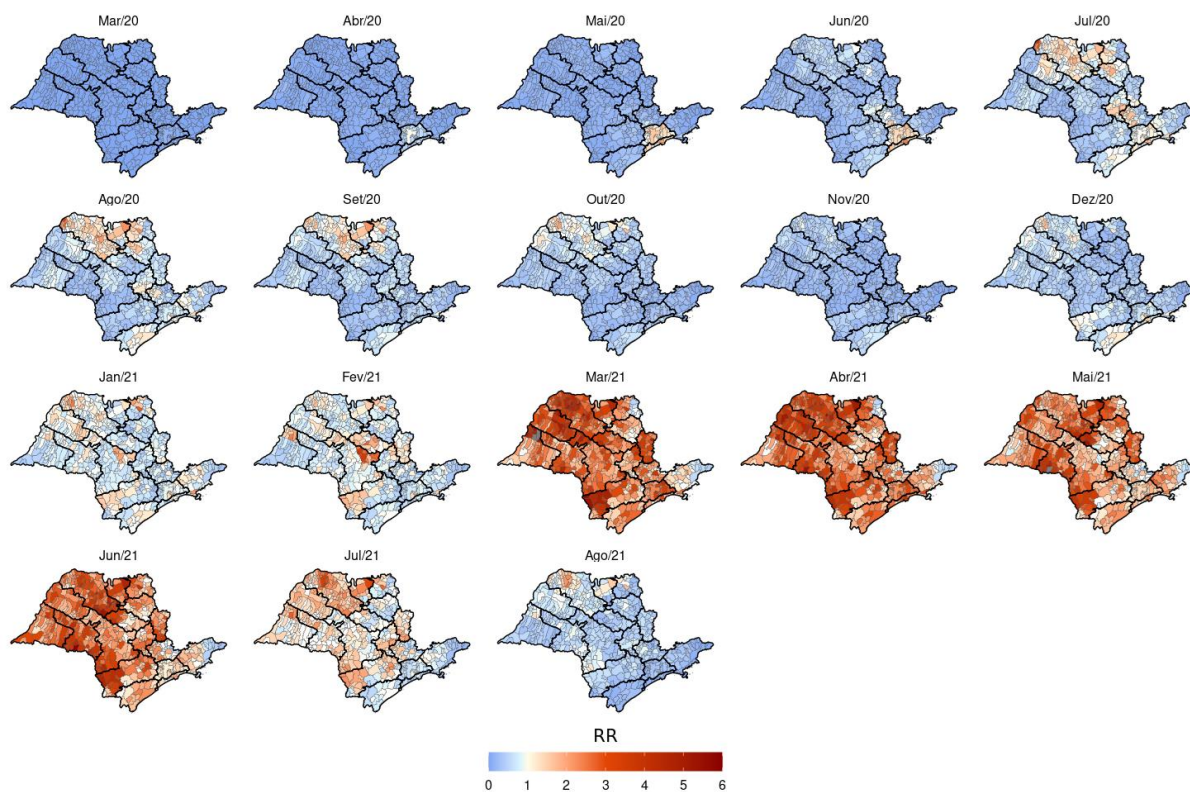
As estimativas médias da interação espaço-tempo (δ) para óbitos estão ilustradas na Figura S7. Em 2020, os padrões são similares aos encontrados para casos, onde verifica-se a introdução da doença e o maior risco na região metropolitana de São Paulo e Baixada Santista ao longo dos quatro primeiros meses, e a posterior concentração de óbitos entre as regiões de saúde de São José do Rio Preto e Barretos. No ano de 2021, destaca-se algumas regiões que apresentaram altos valores de δ para óbitos e não para casos. Esse é o caso para a região Oeste do DRS Sorocaba e para o Nordeste do DRS Bauru, assim como para o DRS de São João da Boa Vista em geral.

Figura S7: Efeitos da interação espaço-tempo exponenciados para modelo estatístico para óbitos por SRAG-COVID por Região de Saúde, a cada mês.



A distribuição espaço-temporal dos riscos relativos (RR) para óbitos por SRAG-COVID se encontra na Figura S8. No geral, os padrões apresentados se assemelham aos padrões descritos para casos (Figura 14), porém com um período de um mês de atraso. Vê-se a concentração dos maiores riscos na Grande São Paulo e na Baixada Santista durante os quatro primeiros meses, e a transição para os DRS do interior – principalmente São José do Rio Preto, Barretos e Ribeirão Preto – a partir de julho de 2020. Após uma concentração de valores baixos no final daquele ano, os riscos voltam a subir em 2021 de forma a concentrar riscos altos ($RR > 2$) a partir de março de 2021, sendo abril o mês de pior situação.

Figura S8: Risco relativo (RR) para óbitos de SRAG-COVID estimado pelo modelo estatístico (média) entre os municípios em cada mês.



Nas Figuras S9 e S10 estão expostas as probabilidades dos riscos para casos e óbitos, respectivamente, ser maior do que 1 entre as regiões ao longo dos meses. Tal visualização permite analisar as incertezas envolvidas na estimação dos riscos. Alguns padrões se repetem aos já observados: como as primeiras altas probabilidades se manifestarem nos DRS Grande São Paulo e Baixada Santista, ao longo dos meses de maio e junho e posteriormente nos DRS de Noroeste paulista, ao longo de julho, agosto e setembro de 2020. Poucos municípios apresentaram altas probabilidades a partir de outubro, e foi só a partir de janeiro de 2021 que tais probabilidades voltaram a subir de forma que de março a maio de 2021, todos os DRS concentravam boa parte de seus municípios com alta probabilidade do risco para casos e óbitos ser maior do que 1.

Figura S9: Probabilidades do risco relativo (RR) estimado para casos de SRAG-COVID ser maior do que 1 em cada município, em cada mês.

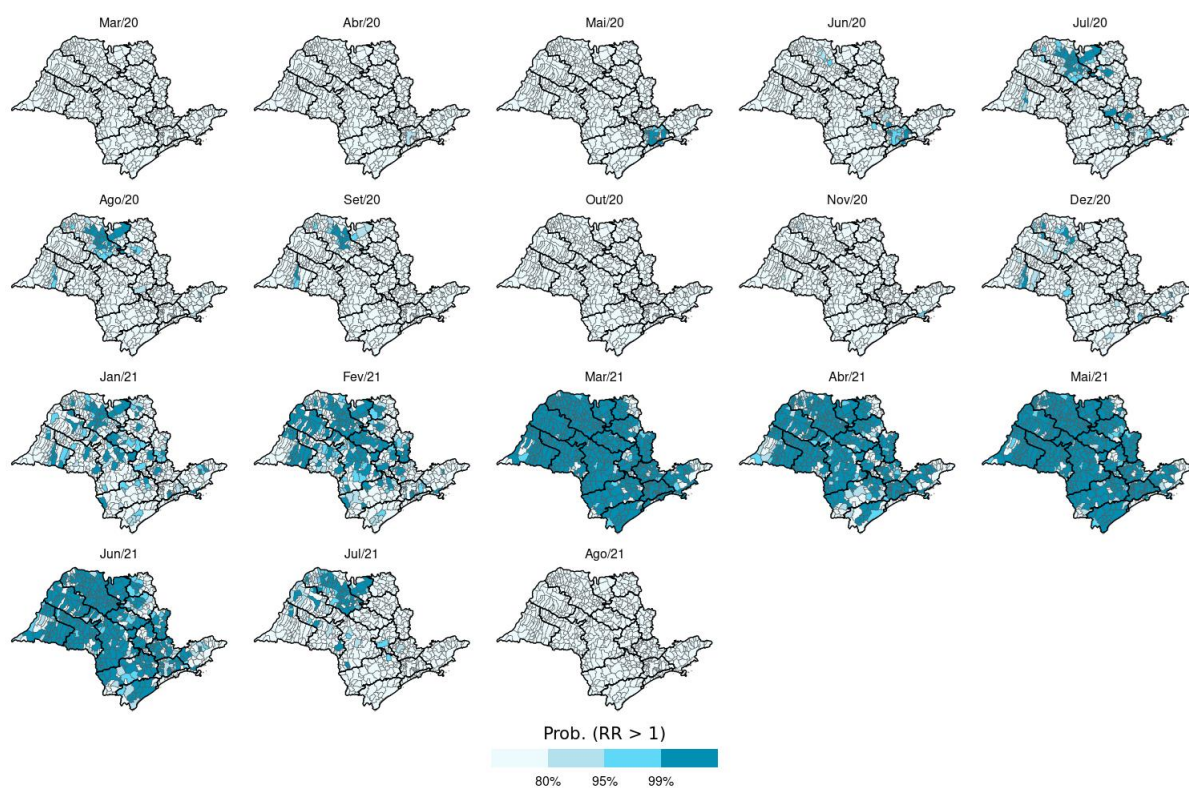
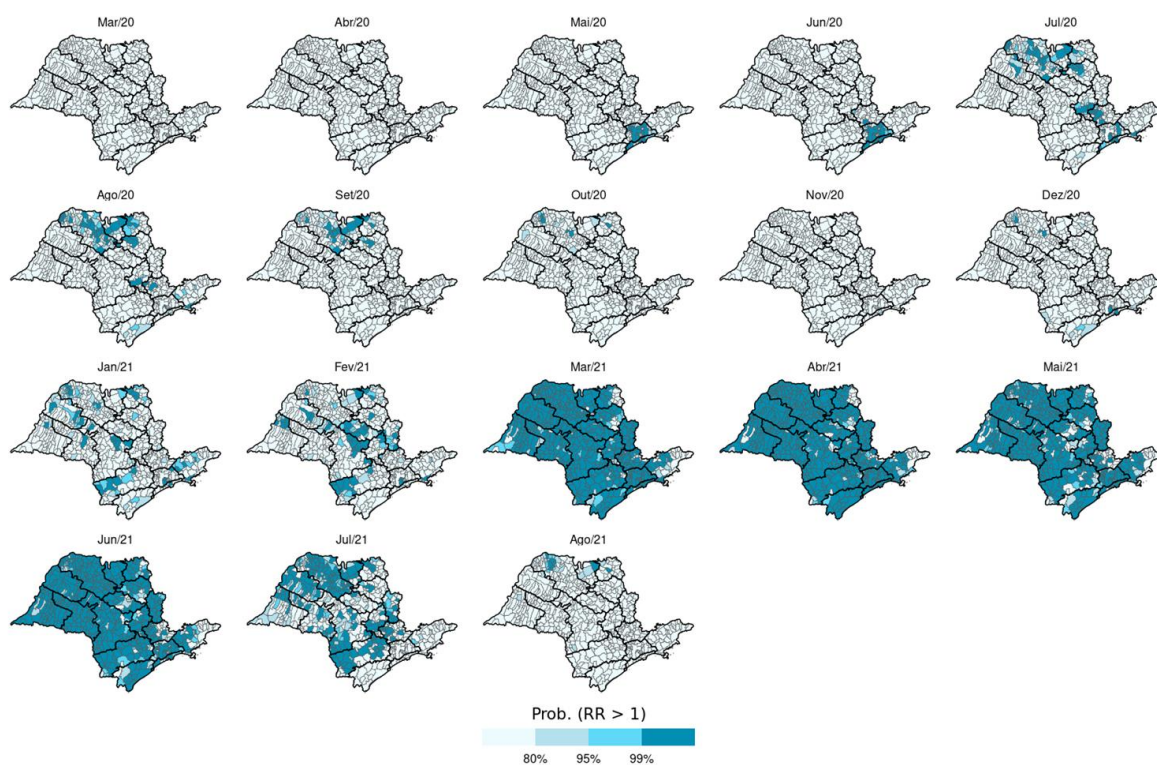


Figura S10: Probabilidades do risco relativo (RR) estimado para óbitos de SRAG-COVID ser maior do que 1 em cada município, em cada mês.



ANEXO A – COMPOSIÇÃO DO GEOSSES

Variáveis utilizadas para composição do GeoSES. Extraído de Barrozo e colaboradores (2020).

Quadro A1: Descrição das variáveis que compõem o índice GeoSES. Fonte: Barrozo et al., 2020.

VARIÁVEL	DESCRIÇÃO
Dimensão “Educação”	
P_GRAD	porcentagem de pessoas cuja espécie do curso mais elevado concluído foi graduação
P_MEST	porcentagem de pessoas cuja espécie do curso mais elevado concluído foi mestrado
P_DOUTOR	porcentagem de pessoas cuja espécie do curso mais elevado concluído foi doutorado
P_SEM_INST	porcentagem de pessoas cujo nível de instrução é o sem instrução e fundamental incompleto
P_FUND	porcentagem de pessoas cujo nível de instrução é o fundamental completo e médio incompleto
P_ENSMED	porcentagem de pessoas cujo nível de instrução é o Médio completo e superior incompleto
P_ENSSUP	porcentagem de pessoas cujo nível de instrução é o superior completo
Dimensão “Mobilidade”	
P_OUTROMUNC	porcentagem de pessoas que trabalha em outro município
P_CASADIA	porcentagem de pessoas que retorna diariamente do trabalho para casa
P_ATE5	porcentagem de pessoas cujo tempo habitual gasto de deslocamento de sua casa até o trabalho é de até 5 minutos
P_6A30	porcentagem de pessoas cujo tempo habitual gasto de deslocamento de sua casa até o trabalho é de até 6 a 30 minutos

P_1A2	porcentagem de pessoas cujo tempo habitual gasto de deslocamento de sua casa até o trabalho é de 1 a 2 horas
P_MAISDE2	porcentagem de pessoas cujo tempo habitual gasto de deslocamento de sua casa até o trabalho é de mais de 2 horas
Dimensão “Pobreza”	
MEDIA_DENSMORA	densidade de morador por cômodo
P_POBREZA	% de pessoas na linha da pobreza: cujo rendimento domiciliar per capita é menor ou igual a R\$255,00 (meio salário mínimo em 2010)
P_PPI_POBREZA	% de pessoas na linha da pobreza e de raça ou etnia preta, parda ou indígena
P_BOLSA_FAM	porcentagem de pessoas que em julho de 2010, tinham rendimento mensal habitual de Programa Social Bolsa-Família ou Programa de Erradicação do Trabalho Infantil (PETI)
P_OUTROSPROG	porcentagem de pessoas que em julho de 2010, tinham rendimento mensal habitual de outros programas sociais ou de transferências
Dimensão “Privação Material”	
P_ALVSREV	porcentagem de domicílios de alvenaria sem revestimento
P_REDE_ESG	porcentagem de domicílios com rede geral de esgoto
P_REDE_AGUA	porcentagem de domicílios com rede geral de distribuição de água
P_LIXO	porcentagem de domicílios com lixo coletado diretamente por serviço de limpeza
P_ENERGIA	porcentagem de domicílios com energia elétrica de companhia distribuidora de energia
P_TV	porcentagem de domicílios com existência de TV
P_MAQLAV	porcentagem de domicílios com existência de máquina de lavar

	roupa
P_GELADEIRA	porcentagem de domicílios com existência de geladeira
P_MAQTVGEL	porcentagem de domicílios com existência de máquina de lavar, TV e geladeira
P_CELULAR	porcentagem de domicílios com existência de celular
P_COMP_INT	porcentagem de domicílios com existência de computador com acesso à internet
P_CELCOMPINT	porcentagem de domicílios com existência de telefone celular e computador com internet
P_MOTO	porcentagem de domicílios com existência de motocicleta para uso particular
P_CARRO	porcentagem de domicílios com existência de automóvel para uso particular
P_ADEQ	porcentagem de domicílios com moradia adequada
P_TUDOADEQ	porcentagem de domicílios com acesso a rede de esgoto, rede de água, coleta de lixo, energia elétrica e moradia adequada
P_NEM_MOTO_CARRO	porcentagem de domicílios sem moto ou carro para uso particular
P_SO_MOTO	porcentagem de domicílios com existência de apenas moto para uso particular
P_SO_CARRO	porcentagem de domicílios com existência de apenas carro para uso particular
Dimensão “Renda”	
MED_RENDDOM	rendimento mensal domiciliar em julho de 2010
Dimensão “Riqueza”	
P_ALUG1000	porcentagem de domicílios alugados com valor de aluguel de R\$1000,00 ou mais
P_BANH4OUMAI	porcentagem de domicílios com 4 banheiros ou mais

S	
P_IDOSO10SM	% de pessoas de 65 anos ou mais com rendimento mensal igual ou acima de R\$5100,00 (ou 10 salários mínimos)
Dimensão “Segregação”	
ICE_renda	(número de pessoas com renda acima de R\$5400,00-número de pessoas com renda abaixo de R\$1000,00)/número de pessoas que responderam [os valores foram calculados com base nos percentis 20 e 80 do rendimento V6529 da planilha PESSOA dos microdados do Censo de 2010]
ICEedu	(número de pessoas com ensino superior completo- número de pessoas sem instrução e fundamental incompleto)/total de pessoas que responderam [V6400]
ICE_renda_preto	(número de brancos com rendimento acima de R\$5400,00-número de pretos com rendimento igual ou menor do que R\$1000,00)/total de pessoas que responderam as duas perguntas [V6529 e V0606]
ICE_renda_ppi	(número de brancos com rendimento acima de R\$5400,00-número de pretos+pardos + indígenas com rendimento igual ou menor do que R\$1000,00)/total de pessoas que responderam as duas perguntas [V6529 e V0606]
ICE_branco_renda	(número de brancos com rendimento acima de R\$5400,00-número de brancos com rendimento igual ou menor do que R\$1000,00)/total de pessoas que responderam as duas perguntas [V6529 e V0606]

ANEXO B – COMPOSIÇÃO DO IVS

Variáveis utilizadas para cálculo de cada um dos três indicadores que compõem o Índice de Vulnerabilidade Social (IVS) (IPEA, 2015).

Quadro B1: Variáveis utilizadas em cada um dos três índices que compõem o Índice de Vulnerabilidade Social (IVS). Fonte: IPEA, 2015.

Indicador	Descrição	Peso
IVS Infraestrutura Urbana		
a) Percentual de pessoas em domicílios com abastecimento de água e esgotamento sanitário inadequados	Razão entre o número de pessoas que vivem em domicílios cujo abastecimento de água não provém de rede geral e cujo esgotamento sanitário não é realizado por rede coletora de esgoto ou fossa séptica, e a população total residente em domicílios particulares permanentes, multiplicada por 100. São considerados apenas os domicílios particulares permanentes.	0,3
b) Percentual da população que vive em domicílios urbanos sem serviço de coleta de lixo	Razão entre a população que vive em domicílios sem coleta de lixo e a população total residente em domicílios particulares permanentes, multiplicada por 100. Estão incluídas as situações em que a coleta de lixo é realizada diretamente por empresa pública ou privada, ou o lixo é depositado em caçamba, tanque ou depósito fora do domicílio, para posterior coleta pela prestadora do serviço. São considerados apenas os domicílios particulares permanentes, localizados em área urbana.	0,3
c) Percentual de pessoas que vivem em domicílios com renda per capita inferior a meio salário	Razão entre o número de pessoas ocupadas, de 10 anos ou mais de idade, que vivem em domicílios com renda per capita inferior a meio salário mínimo, de agosto de 2010, e que gastam mais de uma hora em	0,4

mínimo e que gastam mais de uma hora até o trabalho no total de pessoas ocupadas, vulneráveis e que retornam diariamente do trabalho	deslocamento até o local de trabalho, e o total de pessoas ocupadas nessa faixa etária que vivem em domicílios com renda per capita inferior a meio salário mínimo, de agosto de 2010, e que retornam diariamente do trabalho, multiplicado por 100.	
IVS Capital Humano		
a) Mortalidade até um ano de idade	Número de crianças que não deverão sobreviver ao primeiro ano de vida, em cada mil crianças nascidas vivas.	0,125
b) Percentual de crianças de 0 a 5 anos que não frequentam a escola	Razão entre o número de crianças de 0 a 5 anos de idade que não frequentam creche ou escola, e o total de crianças nesta faixa etária (multiplicada por 100).	0,125
c) Percentual de pessoas de 6 a 14 anos que não frequentam a escola	Razão entre o número de pessoas de 6 a 14 anos que não frequentam a escola, e o total de pessoas nesta faixa etária (multiplicada por 100).	0,125
d) Percentual de mulheres de 10 a 17 anos de idade que tiveram filhos	Razão entre o número de mulheres de 10 a 17 anos de idade que tiveram filhos, e o total de mulheres nesta faixa etária (multiplicada por 100).	0,125
e) Percentual de mães chefes de família, sem fundamental completo e com pelo menos um filho menor de 15 anos de idade, no total de mães chefes de família	Razão entre o número de mulheres que são responsáveis pelo domicílio, que não têm o ensino fundamental completo e têm pelo menos um filho de idade inferior a 15 anos morando no domicílio, e o número total de mulheres chefes de família (multiplicada por 100). São considerados apenas os domicílios particulares permanentes.	0,125
f) Taxa de analfabetismo da população de 15 anos ou mais de idade	Razão entre a população de 15 anos ou mais de idade que não sabe ler nem escrever um bilhete simples, e o total de pessoas nesta faixa etária (multiplicada por 100)	0,125

g) Percentual de crianças que vivem em domicílios em que nenhum dos moradores tem o ensino fundamental completo	Razão entre o número de crianças de até 14 anos que vivem em domicílios em que nenhum dos moradores tem o ensino fundamental completo, e a população total nesta faixa etária residente em domicílios particulares permanentes (multiplicada por 100).	0,125
h) Percentual de pessoas de 15 a 24 anos que não estudam, não trabalham e possuem renda domiciliar per capita igual ou inferior a meio salário mínimo (2010), na população total dessa faixa etária	Razão entre as pessoas de 15 a 24 anos que não estudam, não trabalham e com renda per capita inferior a meio salário mínimo, de agosto de 2010, e a população total nesta faixa etária (multiplicada por 100). São considerados apenas os domicílios particulares permanentes	0,125
IVS Renda e Trabalho		
a) Proporção de pessoas com renda domiciliar per capita igual ou inferior a meio salário mínimo (2010)	Proporção dos indivíduos com renda domiciliar per capita igual ou inferior a R\$ 255,00 mensais (em reais de agosto de 2010), equivalente a meio salário mínimo nessa data. O universo de indivíduos é limitado àqueles que vivem em domicílios particulares permanentes.	0,2
b) Taxa de desocupação da população de 18 anos ou mais de idade	Percentual da população economicamente ativa (PEA) nessa faixa etária que estava desocupada, ou seja, que não estava ocupada na semana anterior à data do censo, mas havia procurado trabalho ao longo do mês anterior à data dessa pesquisa.	0,2
c) Percentual de pessoas de 18 anos ou mais sem fundamental completo e em ocupação informal	Razão entre as pessoas de 18 anos ou mais sem fundamental completo, em ocupação informal, e a população total nesta faixa etária, multiplicada por 100. Ocupação informal implica que trabalham, mas não são: empregados com carteira de trabalho assinada, militares do exército, da marinha, da aeronáutica, da polícia militar ou do corpo de	0,2

	bombeiros, empregados pelo regime jurídico dos funcionários públicos ou empregadores e trabalhadores por conta própria com contribuição a instituto de previdência oficial.	
d) Percentual de pessoas em domicílios com renda per capita inferior a meio salário mínimo (de 2010) e dependentes de idosos	Razão entre as pessoas que vivem em domicílios com renda per capita inferior a meio salário mínimo, de agosto de 2010, e nos quais a renda de moradores com 65 anos ou mais de idade (idosos) corresponde a mais da metade do total da renda domiciliar, e a população total residente em domicílios particulares permanentes (multiplicada por 100).	0,2
e) Taxa de atividade das pessoas de 10 a 14 anos de idade	Razão das pessoas de 10 a 14 anos de idade que eram economicamente ativas, ou seja, que estavam ocupadas ou desocupadas na semana de referência do censo entre o total de pessoas nesta faixa etária (multiplicada por 100). Considera-se desocupada a pessoa que, não estando ocupada na semana de referência, havia procurado trabalho no mês anterior a essa pesquisa.	0,2