

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

OKSANA KUCZYNSKI

**MINIMIZAÇÃO DE ANOS DE VIDA PERDIDOS EM EVENTOS EPIDÊMICOS
CONSIDERANDO ASPECTOS ECONÔMICOS**

CURITIBA

2023

OKSANA KUCZYNSKI

**MINIMIZAÇÃO DE ANOS DE VIDA PERDIDOS EM EVENTOS EPIDÊMICOS
CONSIDERANDO ASPECTOS ECONÔMICOS**

**Minimization of Years of Life Lost in epidemic events considering economic
aspects**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia, do Programa de Pós-Graduação em Engenharia Mecânica e de Materiais da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Engenharia de Manufatura.

Orientadora: Prof.^a Dr.^a Cássia Maria Lie Ugaya.

Coorientador: Prof. Dr. Leandro Magatão.

CURITIBA

2023



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Esta licença permite download e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



OKSANA KUCZYNSKI

MINIMIZAÇÃO DE ANOS DE VIDA PERDIDOS EM EVENTOS EPIDÊMICOS CONSIDERANDO ASPECTOS ECONÔMICOS

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Engenharia De Manufatura.

Data de aprovação: 30 de Agosto de 2023

Dra. Cassia Maria Lie Ugaya, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Jaqueline Severino Da Costa, Doutorado - Universidade Federal de Lavras (Ufla)

Dra. Lucia Valeria Ramos De Arruda, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 30/08/2023.

Ao meu irmão (*in memoriam*).

AGRADECIMENTOS

Agradeço à minha orientadora, a Prof.^a Dr.^a Cássia Maria Lie Ugaya, por todo o conhecimento compartilhado durante este mestrado, por toda a compreensão nos momentos difíceis e pela confiança em meu trabalho.

Gostaria de expressar minha profunda gratidão ao Prof. Dr. Leandro Magatão, que generosamente aceitou ser meu coorientador e dedicou um dos recursos mais valiosos, o seu tempo. Sem o seu vasto conhecimento e sua escuta paciente, este trabalho jamais teria sido concluído.

Gostaria de estender minha gratidão à Prof.^a Dr.^a Lucia Valéria Ramos de Arruda e à Prof.^a Dr.^a Jaqueline Severino da Costa, que participaram de minha banca de qualificação e forneceram contribuições valiosas para este trabalho.

Agradeço também a todos os professores que ministraram disciplinas com excelência e ao coordenador do Programa de Pós-Graduação em Engenharia Mecânica e Materiais, o Prof. Dr. Lucas Freitas Berti.

Agradeço aos meus colegas do Centro de Avaliação da Sustentabilidade do Ciclo de Vida (Gyro), que tornaram os momentos de trabalho mais agradáveis, mesmo durante o período em que estávamos isolados e trabalhando remotamente.

Gostaria de expressar minha profunda gratidão à minha família, especialmente aos meus pais, Mariluz Kuczynski e Rosteslau Kuczynski, por proporcionarem absolutamente tudo para que seus filhos pudessem se dedicar exclusivamente aos estudos. Sou abençoada por tê-los ao meu lado.

Agradeço ao meu irmão, Níkolás Kuczynski (*in memoriam*), com quem compartilhei uma infinidade de assuntos relacionados à UTFPR nos últimos anos. Compartilhamos a engenharia, cafés, materiais, cursos, dificuldades e conquistas. E eu, que sempre te encorajava a não desistir, agora só não desisti por você.

Agradeço à minha vó, a baba Teresa Prsybyszewski, e ao meu tio, Hamilton Prsybyszewski, que sempre abrem as portas da sua casa, me oferecendo um refúgio e um café da tarde.

Quero agradecer ao meu companheiro de vida, José Luis Bubniak, que está sempre do meu lado desde o início da minha trajetória acadêmica, tornando os meus dias muito melhores.

Também expresso minha gratidão à UTFPR, pela educação gratuita e de qualidade que recebi ao longo de toda minha jornada acadêmica. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Por fim, obrigada Maria, mãe de Deus, que passou na frente de todas as dificuldades e iluminou o meu caminho.

tem os que passam
e tudo se passa
com passos já passados

tem os que partem
da pedra ao vidro
deixam tudo partido

e tem, ainda bem,
os que deixam
a vaga impressão
de ter ficado

(RUIZ, 2008).

RESUMO

A pandemia de COVID-19 ocasionou enormes perdas humanas e econômicas. Com a rápida disseminação e poucas informações no início da doença, governos em todo o mundo adotaram diversas intervenções não farmacêuticas para tentar mitigar ou suprimir as infecções. De modo a mensurar as perdas humanas e econômicas ocasionadas pela pandemia sob uma visão de impactos na saúde humana, utilizou-se o indicador de Anos de Vida Perdidos. Este estudo, portanto, teve como objetivo desenvolver um modelo matemático para minimizar os Anos de Vida Perdidos em situações de eventos epidêmicos, que considere a adoção de intervenções não farmacêuticas e os seus efeitos na economia. Seguindo as diretrizes da declaração PRISMA, foi conduzida uma revisão sistemática da literatura para encontrar modelos que pudessem servir como base para o desenvolvimento do modelo matemático proposto neste trabalho. O modelo proposto determina a alocação ideal de intervenções não farmacêuticas e considera as capacidades de recursos de saúde para minimizar os Anos de Vida Perdidos de uma população, decorrentes tanto das perdas humanas quanto das perdas econômicas causadas pela COVID-19. O modelo desenvolvido foi formulado como uma Programação Não Linear Inteira Mista, o qual foi transformado em um modelo de Programação Linear Inteira Mista por meio da linearização dos termos quadráticos. Aplicou-se o modelo utilizando dados reais da pandemia de COVID-19 para as 27 unidades da federação do Brasil, considerando três cenários distintos. Os resultados apontam para a predominância de Anos de Vida Perdidos provenientes das perdas econômicas. Os resultados destacam a utilidade do modelo ao fornecer orientações aos tomadores de decisão em relação a um portfólio de intervenções não farmacêuticas, levando em consideração o impacto dessas decisões na saúde e na economia, a fim de minimizar os impactos potenciais na saúde humana. O modelo e as análises também podem ser estendidos para o gerenciamento de eventuais epidemias futuras.

Palavras-chave: intervenções não farmacêuticas; anos de vida perdidos; programação inteira mista; controle epidêmico; COVID-19.

ABSTRACT

The COVID-19 pandemic has caused huge human and economic losses. With the rapid spread and little information on the onset of the disease, governments around the world have adopted several non-pharmaceutical interventions to try to mitigate or suppress infections. In order to measure the human and economic losses caused by the pandemic from a perspective of impacts on human health, the Years of Life Lost indicator was used. Therefore, this study aimed to develop a mathematical model to minimize the years of life lost in situations of epidemic events, which considers the adoption of non-pharmaceutical interventions and their effects on the economy. Following the guidelines of the PRISMA statement, a systematic review of the literature was conducted to find models that could serve as a basis for developing the mathematical model proposed in this work. The proposed model determines the ideal allocation of non-pharmaceutical interventions and considers the capacities of health resources, to minimize the Years of Life Lost in a population, resulting from both human and economic losses caused by COVID-19. The developed model was formulated as a Mixed Integer Nonlinear Programming, which was transformed into a Mixed Integer Linear Programming model through the linearization of the quadratic terms. The model was applied using real data from the COVID-19 pandemic for the 27 federated units of Brazil, considering three different scenarios. The results indicate the predominance of Years of Life Lost resulting from economic losses. The results highlight the model's usefulness guiding decision-makers regarding a portfolio of non-pharmaceutical interventions, considering the impact of these decisions on health and the economy, to minimize potential impacts on human health. The model and the analyses can also be extended to manage eventual future epidemics.

Keywords: non-pharmaceutical interventions; years of life lost; mixed integer programming; epidemic control; COVID-19.

LISTA DE ILUSTRAÇÕES

Figura 1 – Etapas da revisão da literatura.....	19
Figura 2 – Número de artigos selecionados nas bases científicas	22
Figura 3 – Fluxograma PRISMA do processo de revisão sistemática	25
Figura 4 – Esquema do modelo compartimental SICRM	36
Figura 5 – Decisões de INF por UF para o cenário base.....	68
Figura 6 – Decisões de INF por UF para os cenários 1 e 2	78
Gráfico 1 – Expectativa de vida ao nascer em relação ao PIB <i>per capita</i>	62
Gráfico 2 – Anos de Vida Perdidos por UF	65
Gráfico 3 – Anos de Vida Perdidos por 100.000 habitantes por UF	67
Gráfico 4 – Número acumulado de infectados por semana no Brasil	70
Gráfico 5 – Número acumulado de mortos por semana no Brasil.....	71
Gráfico 6 – Número de indivíduos críticos por semana no Brasil	72
Gráfico 7 – Escassez de leitos regulares por UF.....	72
Gráfico 8 – Escassez de leitos de UTI por UF	73
Quadro 1 – Palavras-chave e estratégia para varredura nas bases	21
Quadro 2 – Resumo dos trabalhos descritos na revisão bibliográfica	31
Quadro 3 – Intervenções não farmacêuticas	38
Quadro 4 – Lista de índices e conjuntos do modelo.....	39
Quadro 5 – Lista de parâmetros do modelo.....	39
Quadro 6 – Lista de variáveis do modelo.....	41
Quadro 7 – Resumo dos parâmetros epidêmicos do modelo	56
Quadro 8 – Resumo dos parâmetros relativos ao número de indivíduos.....	58
Quadro 9 – Resumo dos parâmetros relacionados aos recursos médicos	59
Quadro 10 – Resumo dos parâmetros populacionais, econômicos e de mortalidade.....	60

LISTA DE TABELAS

Tabela 1 – Anos de Vida Perdidos por UF para o cenário base	63
Tabela 2 – Anos de Vida Perdidos por 100.000 habitantes por UF	66
Tabela 3 – Principais resultados para o cenário 1	76
Tabela 4 – Principais resultados para o cenário 2	77
Tabela 5 – Análise de sensibilidade do parâmetro ΔPIB_{ki}	80
Tabela 6 – Análise de sensibilidade do parâmetro α_i	80
Tabela 7 – Parâmetros do modelo por UF	111
Tabela 8 – Parâmetros do modelo por UF	112

LISTA DE ABREVIATURAS E SIGLAS

ACV-S	Avaliação do Ciclo de Vida Social
AIDS	Síndrome da Imunodeficiência Adquirida
AVAI	Anos de Vida Ajustados por Incapacidade
AVI	Anos Vividos com Incapacidade
AVP	Anos de Vida Perdidos
CDC	<i>Centers for Disease Control and Prevention</i>
CFM	Conselho Federal de Medicina
CID	Classificação Internacional de Doenças
CMA-ES	<i>Covariance Matrix Adaptation Evolution Strategy</i>
CNES	Cadastro Nacional dos Estabelecimentos de Saúde do Brasil
CONASS	Conselho Nacional de Secretários de Saúde
COVID-19	<i>Coronavirus Disease 2019</i>
DALY	<i>Disability Adjusted Life Years</i>
EGC	Modelo de Equilíbrio Geral Computável
EPIs	Equipamentos de Proteção Individual
ESPII	Emergência de Saúde Pública de Importância Internacional
EUA	Estados Unidos da América
Fiocruz	Fundação Oswaldo Cruz
FMI	Fundo Monetário Internacional
HIV	Vírus da Imunodeficiência Humana
IBGE	Instituto Brasileiro de Geografia e Estatística
INF	Intervenções Não Farmacêuticas
LTM	Lógica Temporal Métrica
MERS	Síndrome Respiratória do Oriente Médio
OMS	Organização Mundial da Saúde
OPAS	Organização Pan-Americana Da Saúde
PIB	Produto Interno Bruto
PLI	Programação Linear Inteira
PLIM	Programação Linear Inteira Mista
PNL	Programação Não Linear
PNLIM	Programação Não Linear Inteira Mista

PRISMA	<i>Preferred Reporting Items for Systematic reviews and Meta-Analyses</i>
QALY	Anos de Vida Ajustados pela Qualidade
SARS	Síndrome Respiratória Aguda Grave
SARS-CoV-2	<i>Severe Acute Respiratory Syndrome Coronavirus 2</i>
SEAIRD	Suscetível, Exposto, Infectado assintomático, Infectado sintomático, Recuperado, Morto
SEIHRA	Suscetível, Exposto, Infectado, Hospitalizado, Recuperado e Assintomático parcialmente infeccioso
SEIR	Suscetível, Exposto, Infectado, Recuperado
SICRM	Suscetível, Infectado, Crítico, Recuperado, Morto
SIR	Suscetível, Infectado, Recuperado
SIRCQTHE	Suscetível, Infectado, Removido, Contagioso não detectado, Quarentena, Ameaçado, Recuperado, Morto
SIRD	Suscetível, Infectado, Recuperado, Morto
SITRFB	Suscetível, Infectado, Tratado, Recuperado, Funeral, Enterrado
SIXHCRD	Suscetível, Infectado testado, Infectado não testado assintomático, Hospitalizado, UTI, Recuperado, Morto
SUQC	Suscetível, Infectado sem quarentena, Infectado em quarentena, Infectado confirmado
UF	Unidades da Federação
USAID	<i>United States Agency for International Development</i>
UTI	Unidade de Terapia Intensiva
WHO	<i>World Health Organization</i>
YLL	<i>Years of Life Lost</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Justificativa.....	17
1.2	Estrutura do trabalho	18
2	REVISÃO DA LITERATURA	19
2.1	Etapa de planejamento	20
2.2	Etapa de revisão	20
2.3	Etapa de seleção	22
2.4	Conteúdo dos artigos	25
3	MODELO MATEMÁTICO	36
3.1	Definição dos parâmetros e variáveis	39
3.2	Função objetivo	42
3.3	Restrições	43
3.3.1	Cenário base	43
3.3.2	Cenário 1: viabilidade de gestão	50
3.3.3	Cenário 2: capacidade de leitos de UTI.....	51
3.4	Linearização do modelo.....	52
4	RESULTADOS E DISCUSSÕES	56
4.1	Configuração dos parâmetros.....	56
4.2	Resultados da implementação.....	63
4.2.1	Resultados para o cenário base	63
4.2.2	Resultados para os cenários 1 e 2	75
4.3	Análise de sensibilidade	79
5	CONSIDERAÇÕES FINAIS	82
	REFERÊNCIAS.....	87
	APÊNDICE A - Lista de verificação da Declaração PRISMA.....	99
	APÊNDICE B - Modelo matemático linearizado	105
	APÊNDICE C - Valores dos parâmetros do modelo por UF.....	110

1 INTRODUÇÃO

O surgimento e a disseminação de várias doenças infecciosas com potencial pandêmico ocorreram ao longo da história. No século passado, a humanidade enfrentou três pandemias de gripe, das quais a mais devastadora foi a Gripe Espanhola, entre 1918 e 1919, causada por um vírus Influenza A/H1N1 e que acarretou aproximadamente 50 milhões de mortes. Mais recentemente, ocorreram epidemias de Síndrome Respiratória Aguda Grave (SARS), de Síndrome Respiratória do Oriente Médio (MERS) e de Ebola, além de outra pandemia de Influenza A/H1N1 em 2009, as quais deixaram a humanidade em alerta (PIRET; BOIVIN, 2021; WORLD HEALTH ORGANIZATION, 2021).

Atualmente o mundo enfrenta uma nova pandemia, de *Coronavirus Disease 2019* (COVID-19), a qual impôs desafios sem precedentes aos sistemas de saúde, governos e sociedades (NICOLA *et al.*, 2020). Para Schwarcz (2020, p. 13), essa crise pode ser descrita como social, econômica, ambiental, cultural, moral e da saúde. Alguns pesquisadores inclusive defendem o uso do termo sindemia para caracterizar a COVID-19, devido à interação sinérgica entre a COVID-19 e outras condições de saúde existentes, bem como os fatores sociais, econômicos e estruturais que influenciam sua disseminação e impacto (BISPO JÚNIOR; SANTOS, 2021; HORTON, 2020).

Os primeiros casos de COVID-19 em seres humanos, doença causada por um vírus da família dos coronavírus, o *Severe Acute Respiratory Syndrome Coronavirus 2* (SARS-CoV-2), foram relatados inicialmente na cidade de Wuhan, na China, em dezembro de 2019 (WORLD HEALTH ORGANIZATION, 2020a). Após afetar 114 países, a doença foi caracterizada como uma pandemia pela Organização Mundial da Saúde (OMS) em 11 de março de 2020 (WORLD HEALTH ORGANIZATION, 2020b).

Até 10 de março de 2023, a COVID-19 já havia infectado mais de 676,6 milhões de pessoas e causado cerca de 6,88 milhões de mortes em todo o mundo (JOHNS HOPKINS UNIVERSITY, 2023). Porém, com base no excesso de mortalidade, a OMS admitiu que o número total de mortes diretas ou indiretas associadas à pandemia em 2020 e 2021 foi de aproximadamente 14,9 milhões (intervalo de 13,3–16,6 milhões), número três vezes maior do que o apontado por dados oficiais (WORLD HEALTH ORGANIZATION, 2022). Um estudo conduzido por

Wang *et al.* (2022) apontou para resultados semelhantes, estimando que cerca de 18,2 milhões (intervalo de 17,1–19,6 milhões) de pessoas morreram em todo o mundo devido à pandemia neste mesmo período.

Além de perdas humanas, a COVID-19 também acarretou perdas econômicas, que segundo dados do *World Economic Outlook* de janeiro de 2022 elaborado pelo Fundo Monetário Internacional (FMI), deverão somar cerca de US\$ 13,8 trilhões até 2024 em relação às projeções anteriores à pandemia (AGARWAR *et al.*, 2022, p. 5).

Ainda com a doença em curso¹, a recuperação econômica global ocorre de maneira heterogênea entre os diferentes países, sendo enfraquecida devido à deflagração da guerra na Ucrânia no início de 2022. Conforme projeções, as economias avançadas devem recuperar sua trajetória de tendência pré-pandemia em 2022 e exceder em 0,9% em 2024, enquanto as economias de mercados emergentes e em desenvolvimento (com exceção da China) devem permanecer em 5,5% abaixo da previsão pré-pandemia em 2024. Essas divergências econômicas são consequência de grandes disparidades no acesso a ferramentas para prevenir e tratar a COVID-19 e apoio desigual a políticas para enfrentar o impacto da pandemia (INTERNATIONAL MONETARY FUND, 2021, p. 13). Além disso, vários dos desafios enfrentados pela economia global, como inflação, níveis de endividamento altos, rupturas no abastecimento e incerteza contínua, também são decorrentes da persistência da pandemia no mundo (AGARWAR *et al.*, 2022, p. 5).

No início da pandemia, em resposta à rápida disseminação do vírus, com informações limitadas e na ausência de vacinas e medicamentos para prevenir a doença ou suas complicações, várias intervenções não farmacêuticas (INF) foram implementadas para mitigar ou suprimir as infecções (CHAN; YUAN; CONVERTINO, 2021; FERGUSON *et al.*, 2020; FLAXMAN *et al.*, 2020; LAI *et al.*, 2020; LIU, Yang *et al.*, 2021).

As INF são ações que podem ser adotadas por indivíduos (por exemplo, higiene respiratória e das mãos, uso de máscara, isolamento de doentes e quarentena de expostos) e por comunidades (por exemplo, medidas de distanciamento social e

¹ Mesmo que a OMS tenha declarado o fim da Emergência de Saúde Pública de Importância Internacional (ESPII) referente à COVID-19 em cinco de maio de 2023, a propagação mundial da doença continua caracterizada como uma pandemia, pois ainda são registrados números significativos de casos, hospitalizações e mortes (OPAS, 2023).

fechamentos temporários), com a finalidade de conter a propagação de doenças que são transmitidas de pessoa para pessoa (CDC, 2020; USAID, 2010, p. 54).

A adoção e o apoio a essas INF variou consideravelmente entre os diferentes países e até entre comunidades (FERGUSON *et al.*, 2020, p. 3; KOCHAŃCZYK; LIPNIACKI, 2021, p. 1). Além disso, alguns governos hesitaram ou optaram por não implementar medidas mais restritivas, como ordens de permanência em casa e fechamento de negócios (*lockdowns*), alegando que tais medidas poderiam acarretar altos custos econômicos, sociais e psicológicos (BENDAVID *et al.*, 2021 p. 2; REDLIN, 2022, p. 3).

De fato, Ferguson *et al.* (2020, p. 4) mencionam que algumas dessas medidas, principalmente as de supressão, trazem profundos custos sociais e econômicos que podem impactar significativamente a saúde e o bem-estar a curto e longo prazo. Porém, para os autores é improvável que apenas estratégias de mitigação sejam capazes de prevenir uma sobrecarga dos sistemas de saúde e resultem em uma alta mortalidade. Portanto, o desafio consiste em equilibrar os custos das intervenções com a sua eficácia potencial na redução da disseminação da doença (LAYARD *et al.*, 2020; LIU, Yang *et al.*, 2021; WORLD HEALTH ORGANIZATION, 2020b).

Assim, compreender a eficácia das INF é fundamental, porém complexo, pois esta varia de acordo com o tipo, momento, duração, intensidade e combinações das intervenções, além das condições sociais e políticas do país onde são implementadas (CHAN; YUAN; CONVERTINO, 2021) e do comprometimento da população quanto a sua adesão (KANTOR; KANTOR, 2020). Diversos estudos buscaram avaliar a eficácia e os impactos destas INF sobre o número de infecções e mortes, considerando essas medidas individualmente ou em conjunto, para um único ou vários países, por meio de simulações (DAVIES *et al.*, 2020; FERGUSON *et al.*, 2020; KUCHARSKI *et al.*, 2020; LAI *et al.*, 2020), métodos preditivos (CHOWDHURY *et al.*, 2020; HSIANG *et al.*, 2020; LIU, Yan *et al.*, 2022; LIU, Yang *et al.*, 2021), modelagem probabilística (CHAN; YUAN; CONVERTINO, 2021), modelos hierárquicos bayesianos (BRAUNER *et al.*, 2020; FLAXMAN *et al.*, 2020; SHARMA *et al.*, 2021), ou mesclando ferramentas estatísticas, de inferência e de inteligência artificial (HAUG *et al.*, 2020).

Inclusive, cientes dos problemas causados por longas restrições contínuas, os estudos de Chowdhury *et al.* (2020) e de Singh e Adhikari (2020) avaliaram a implantação de INF dinâmicas, intercalando períodos de distanciamento social mais restritivos com períodos de relaxamento, como uma alternativa mais adequada e

realista. Já outras medidas do portfólio de INF consideradas menos onerosas, como o uso de máscaras faciais e uma melhor higiene das mãos, poderiam ser mantidas e trazer benefícios para a saúde e bem-estar da população mesmo em momentos não pandêmicos, reduzindo substancialmente a incidência geral de doenças infecciosas (OH *et al.*, 2021; ULLRICH *et al.*, 2021).

Jordan *et al.* (2021) reuniram estudos no contexto da COVID-19 que utilizaram técnicas de otimização em tópicos como estratégias de teste, previsão, prevenção e controle, alocação de recursos, priorização da vacinação e ferramentas de apoio à decisão. Dentre os estudos publicados, vários tinham o objetivo de minimizar o número total de infecções e de mortes causadas pela doença (BERTSIMAS *et al.*, 2022; CHEN *et al.*, 2021; EL MEHDI *et al.*, 2021; FREJ *et al.*, 2021; HAN *et al.*, 2021; LIBOTTE *et al.*, 2020; MATRAJT *et al.*, 2021a, 2021b; MORATO *et al.*, 2022; MORRIS *et al.*, 2021).

Outros estudos também buscaram inserir questões econômicas em seus modelos de otimização, de modo a minimizar tanto as mortes quanto as perdas econômicas decorrentes das intervenções (BRANDÃO, 2021; FERCHIOU *et al.*, 2020; GHAMIZI *et al.*, 2020; MIIKKULAINEN *et al.*, 2021; YAESOUBI *et al.*, 2021). Nesse aspecto, uma formulação bastante popular foi a de modelos que combinam fatores macroeconômicos com variações do modelo epidêmico Suscetível-Infeccioso-Recuperado (SIR) e a resolução destes problemas por meio da teoria de controle ótimo (ACEMOGLU *et al.*, 2021; ALVAREZ; ARGENTE; LIPPI, 2021; BARLOW; MARSHALL; TYSON, 2021; BAYRAKTAR; COHEN; NELLIS, 2021; EICHENBAUM; REBELO; TRABANDT, 2021, 2022).

No entanto, estes estudos normalmente apresentam saúde pública e economia como objetivos concorrentes, como se houvesse um *trade-off* entre salvar vidas ou preservar a economia a ser enfrentado pelos formuladores de políticas. Porém, Gourinchas (2020, p. 35) defende que embora isso possa parecer um *trade-off*, não é, pois por mais que medidas de contenção da doença possam acentuar a crise econômica no curto prazo, se não fossem adotadas, uma recessão ocorreria de qualquer maneira devido ao comportamento de precaução e pânico dos agentes econômicos mediante as incertezas de uma pandemia descontrolada. Ao analisar evidências da Gripe Espanhola, Correia, Luck e Verner (2022) também sugerem que a principal fonte de ruptura econômica foi a própria pandemia, não as INF adotadas na época.

Por outro lado, perdas econômicas também podem refletir na condição de vida humana. Preston (1975) mostra que há uma relação empírica entre desenvolvimento econômico e saúde. Essa relação foi utilizada na Avaliação do Ciclo de Vida Social (ACV-S) para quantificar impactos potenciais na saúde humana decorrentes de variações no Produto Interno Bruto (PIB), resultando em indicadores como, por exemplo, *Years of Life Lost* (YLL) ou Anos de Vida Perdidos (AVP) (NORRIS, 2006; FESCHET *et al.*, 2013). O conceito de AVP busca estimar o tempo médio que uma pessoa deixa de viver por ter morrido prematuramente.

Desse modo, considerando que as perdas na saúde humana podem ocorrer tanto pela doença quanto pelos seus impactos na economia, como minimizar os Anos de Vida Perdidos em uma epidemia por meio da adoção de INF?

Assim, o objetivo geral deste trabalho é desenvolver um modelo matemático para minimizar os Anos de Vida Perdidos em situações de eventos epidêmicos, que considere a adoção de INF e os seus efeitos na economia, e testá-lo utilizando dados da literatura relativos à COVID-19.

Com o propósito de atingir o objetivo geral, os seguintes objetivos específicos foram estabelecidos:

- a) Identificar na literatura modelos correlatos ao contexto de trabalho que auxiliem na construção do próprio modelo a ser proposto;
- b) Desenvolver o modelo de otimização conectando as dimensões social e econômica de modo a minimizar os impactos potenciais na saúde humana;
- c) Aplicar o modelo construído considerando as 27 unidades da federação (UF) do Brasil em diferentes cenários;
- d) Realizar uma análise de sensibilidade em parâmetros do modelo para verificar possíveis mudanças significativas nos resultados.

1.1 Justificativa

Mesmo com o rápido desenvolvimento, as vacinas para a COVID-19, por exemplo, levaram cerca de um ano para serem disponibilizadas ao público, além de sua disponibilidade ser limitada inicialmente (PIRET; BOIVIN, 2021; SHIM, 2021). Assim, até que intervenções farmacológicas sejam descobertas ou estejam amplamente disponíveis para os locais afetados, é imperativo que os formuladores de

política implementem em tempo hábil estratégias para conter a disseminação de doenças infecciosas e evitar atingir os limites da capacidade hospitalar. Nesse aspecto, o modelo desenvolvido nesta pesquisa pode ser útil ao dar direcionamento ao formulador de políticas recomendando um portfólio de INF, considerando o impacto sanitário e econômico de suas decisões, de modo a minimizar os AVP da população.

Embora tenha sido aplicado ao contexto da COVID-19, o modelo desenvolvido possui potencial de adaptação e aplicação em outros eventos epidêmicos, para os quais o mundo precisa se preparar. Além disso, neste trabalho optou-se por aplicar o modelo para a realidade brasileira, de modo que INF diferenciadas possam ser adotadas entre os estados, a depender das características e situação epidemiológica de cada um. Como o Brasil possui dimensões continentais e uma grande diversidade socioeconômica entre as regiões e, considerando a decisão de que estados e municípios têm autonomia para decidir sobre medidas de combate à pandemia da COVID-19 (BRASIL, 2020a), o país pode se beneficiar de uma estratégia espacialmente heterogênea.

Ademais, a otimização mostrou-se uma importante ferramenta usada para resolver problemas relacionados à COVID-19, porém foi possível perceber na literatura revisada, que os principais objetivos tratados nos estudos eram minimizar casos ou mortes e maximizar o benefício econômico (JORDAN *et al.*, 2021). Nesta dissertação buscou-se abordar esse problema sob uma ótica diferente, de que perdas econômicas também podem resultar em perdas potenciais na saúde humana. Até onde se tem conhecimento, nenhum dos estudos anteriores investigou essa problemática segundo esta perspectiva.

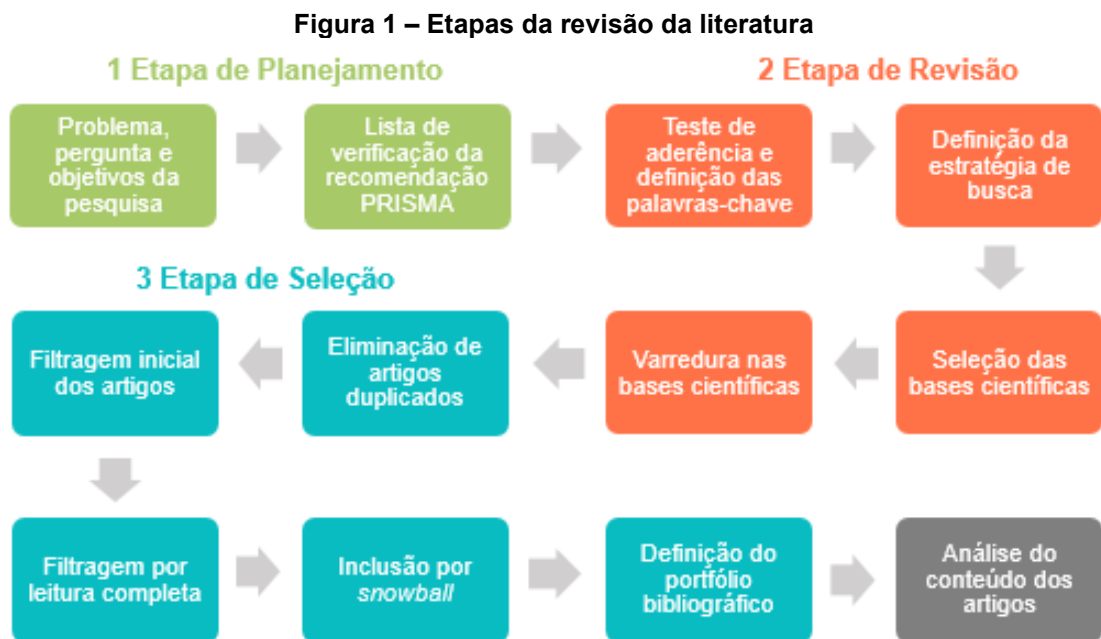
1.2 Estrutura do trabalho

Esta dissertação está estruturada em 5 capítulos. Uma revisão sistemática da literatura relacionada é fornecida no Capítulo 2, de modo a identificar modelos de otimização que abordam INF para o gerenciamento e controle de doenças infecciosas. No Capítulo 3 é apresentado o modelo matemático proposto, descrevendo a função objetivo e as restrições, além de sua linearização. O Capítulo 4 expõe os resultados da aplicação do modelo para o caso de controle da COVID-19 nas 27 UF brasileiras. Já o Capítulo 5 apresenta as considerações finais, as limitações do estudo e sugestões para pesquisas futuras.

2 REVISÃO DA LITERATURA

Com o propósito de identificar modelos que possam servir como base para a formulação do modelo proposto neste estudo, foi realizada uma pesquisa bibliográfica por meio de uma revisão sistemática da literatura, apoiada na declaração *Preferred Reporting Items for Systematic reviews and Meta-Analyses* (PRISMA), a qual foi publicada inicialmente em 2009 e atualizada em 2020. A declaração PRISMA 2020 foi elaborada para auxiliar a relatar de maneira transparente, completa e precisa porquê a revisão foi feita, o que foi feito e encontrado pelos pesquisadores (PAGE *et al.*, 2021).

A realização da revisão sistemática da literatura deste estudo pode ser dividida em três etapas principais e que contêm diversos passos que permitem o seu desenvolvimento, conforme ilustra a Figura 1.



Fonte: Autoria própria, adaptado de GORTZ-BONALDO (2021).

Na sequência, as etapas e passos para a realização da revisão da literatura descritos na Figura 1 são detalhados.

2.1 Etapa de planejamento

A etapa de planejamento compreendeu a identificação da pergunta de pesquisa e a definição dos objetivos que a regem, além do preenchimento da lista de verificação da declaração PRISMA 2020.

A pergunta de pesquisa e os objetivos, separados em geral e específicos, já haviam sido definidos e constam na introdução deste trabalho. Na sequência, de modo a auxiliar na condução da revisão sistemática de literatura, foi utilizada a declaração PRISMA 2020. Assim, fez-se o preenchimento da lista de verificação contendo 27 itens da PRISMA segundo os critérios definidos para a realização desta revisão, a qual se encontra no Apêndice A.

Embora seja utilizada majoritariamente em pesquisas na área da saúde (PAGE *et al.*, 2021), neste trabalho a declaração PRISMA foi usada principalmente para definir e relatar de forma consistente pontos como: tipos e fontes de informação, delimitação temporal, estratégia de busca e processo de filtragem e seleção de artigos para compor o portfólio bibliográfico. Após estas definições, pôde-se conduzir as buscas pela bibliografia requerida.

2.2 Etapa de revisão

Esta etapa foi composta por testes de aderência e combinação de palavras-chave, definição da estratégia de busca, escolha das bases científicas e pela varredura nestas bases.

Inicialmente, foi realizada uma listagem de possíveis palavras-chave com base no tema e nos objetivos da pesquisa, além de leituras que foram feitas anteriormente. Então, foram efetuadas buscas prévias em bases de dados a fim de verificar as palavras-chave e suas combinações que se mostravam mais aderentes ao tema. Para definir as mais adequadas, foram estabelecidos como critérios: a quantidade e consistência das publicações retornadas considerando o objetivo da pesquisa, por meio da leitura dos títulos e resumos (LACERDA; ENSSLIN; ENSSLIN, 2012).

Após a realização dessas buscas prévias, concluiu-se que as oito palavras-chave, separadas em três áreas de pesquisa e listadas no Quadro 1, eram as mais apropriadas para a seleção da amostra de publicações para o tema de pesquisa.

Quadro 1 – Palavras-chave e estratégia para varredura nas bases

Áreas de pesquisa	Palavras-chave	Estratégia de busca
Pesquisa operacional	<i>Integer programming</i> <i>Mixed integer linear programming</i>	(<i>"integer programming" OR "mixed integer linear programming"</i>) AND (<i>"infectious disease" OR epidemic OR pandemic OR COVID</i>) AND (<i>"non-pharmaceutical interventions" OR "epidemic control"</i>)
Epidemiologia	<i>Infectious disease</i> <i>Epidemic</i> <i>Pandemic</i> <i>COVID</i>	
Estratégias de contenção da doença	<i>Non-pharmaceutical interventions</i> <i>Epidemic control</i>	

Fonte: Autoria própria (2023).

A partir dos testes de aderência das palavras-chave e de suas combinações, foi possível definir uma estratégia de busca, que consiste na associação das palavras-chaves com os operadores booleanos, resultando em uma *string* de busca a ser utilizada nas bases científicas, a qual é apresentada no Quadro 1.

Também foram definidas as bases científicas onde as buscas seriam efetuadas. As fontes utilizadas para a pesquisa da literatura foram o *Science Direct*, o *Scopus* e a *Web of Science (WoS)*, devido à abrangência e disponibilidade de uma vasta coleção de bases de dados que são referenciadas nas comunidades científicas.

A varredura nestas bases científicas ocorreu em dezembro de 2022 e a última busca foi realizada no dia 09 de janeiro de 2023, considerando todos os tipos de publicações em inglês, entre os anos de 2018 e 2023 (últimos cinco anos), conforme preenchido na lista de verificação da declaração PRISMA 2020. Essa busca resultou em um total de 75 referências.

A Figura 2 mostra os resultados obtidos nesta etapa de revisão conforme cada uma das bases selecionadas.

Figura 2 – Número de artigos selecionados nas bases científicas



Fonte: Autoria própria (2023).

Na próxima etapa, a partir da filtragem das referências iniciais encontradas, foi feita a seleção do portfólio final de artigos a serem analisados.

2.3 Etapa de seleção

A fim de selecionar apenas as publicações mais relevantes e alinhadas com o objetivo desta pesquisa, processos de filtragem foram realizados. Assim, os próximos passos consistiram na exclusão das referências duplicadas, na triagem por meio de leitura dinâmica, seguida de triagem por meio de leitura integral e em inclusões de artigos seminais frequentemente citados e anteriores ao recorte temporal adotado.

O conteúdo oriundo das bases de dados foi organizado em um gerenciador de referências, o Zotero 6.0.19, o qual foi escolhido por ser um *software* livre. Inicialmente, fez-se a eliminação das referências duplicadas usando um recurso presente no próprio *software*. Das 75 referências encontradas no início, 7 duplicações foram identificadas, restando 68 após a exclusão. Adicionalmente, uma verificação manual foi conduzida, mas nenhuma outra duplicidade foi localizada.

Na sequência foi feita uma filtragem das 68 publicações em relação à relevância e aderência ao tema e objetivos desta pesquisa. Para tanto, realizou-se uma leitura dinâmica do título, resumo e palavras-chave dos artigos e os que não estavam alinhados com os objetivos da pesquisa foram eliminados. Foram desconsiderados os trabalhos que apresentam como foco, por exemplo:

- a) Cadeia de suprimentos: adaptação das operações da cadeia de suprimentos mediante as disrupções ocasionadas pela COVID-19 e medidas restritivas adotadas.

- b) Vacinação: definição de estratégias de vacinação contra a gripe; além de, para a COVID-19, o desenvolvimento de cadeias de suprimento de vacinas de modo geral, modelos de alocação ou distribuição de vacinas e localização de centros de vacinação ou de armazenagem.
- c) Alocação e distribuição de recursos de saúde: no contexto da COVID-19, modelos sobre alocação e distribuição de recursos como Equipamentos de Proteção Individual (EPIs) e testes de detecção, alocação de serviços médicos, localização de instalações de testagem e tratamento, e distribuição de alimentos para indivíduos vulneráveis; no contexto do vírus da imunodeficiência humana (HIV) e da síndrome da imunodeficiência adquirida (AIDS), trabalhos sobre alocação de recursos para a prevenção e o tratamento da doença.
- d) Gestão de resíduos: projetos de rede de logística reversa para gerenciamento eficaz de resíduos hospitalares em surtos epidêmicos.
- e) Logística: tanto no transporte urbano, com o tempo de espera para adentrar em cordão sanitário, a reprogramação de trens e a redução de pico no metrô no contexto da COVID-19, quanto no transporte de cargas, na atracação ótima de navios em portos sob o congestionamento ocasionado pela pandemia.
- f) Palavras-chave utilizadas na busca apareceram ao longo do texto, mas não eram o foco da publicação (sem alinhamento com os objetivos da pesquisa);

Após a aplicação deste primeiro filtro, 51 publicações foram descartadas, restando 17, que constituíram o portfólio bruto a ser analisado.

Foi realizada a leitura completa destes 17 artigos, a qual resultou na eliminação de 4 trabalhos. Estes foram desconsiderados pois não apresentavam modelos matemáticos e se tratavam de: desenvolvimento de algoritmo (AKHTAR *et al.*, 2023); análise de custo-benefício, não havendo otimização (LI, 2023); editorial de revista científica focada no papel da pesquisa operacional em epidemias futuras (FARAHANI; RUIZ; VAN WASSENHOVE, 2023); e revisão sistemática da literatura apoiada na declaração PRISMA 2020 com foco no projeto urbano para melhorar a resiliência das cidades contra doenças infecciosas (YANG *et al.*, 2023).

Desse modo, 13 artigos foram selecionados para constituir o portfólio final (*corpus* dinâmico), os quais tiveram seu conteúdo analisado integralmente buscando

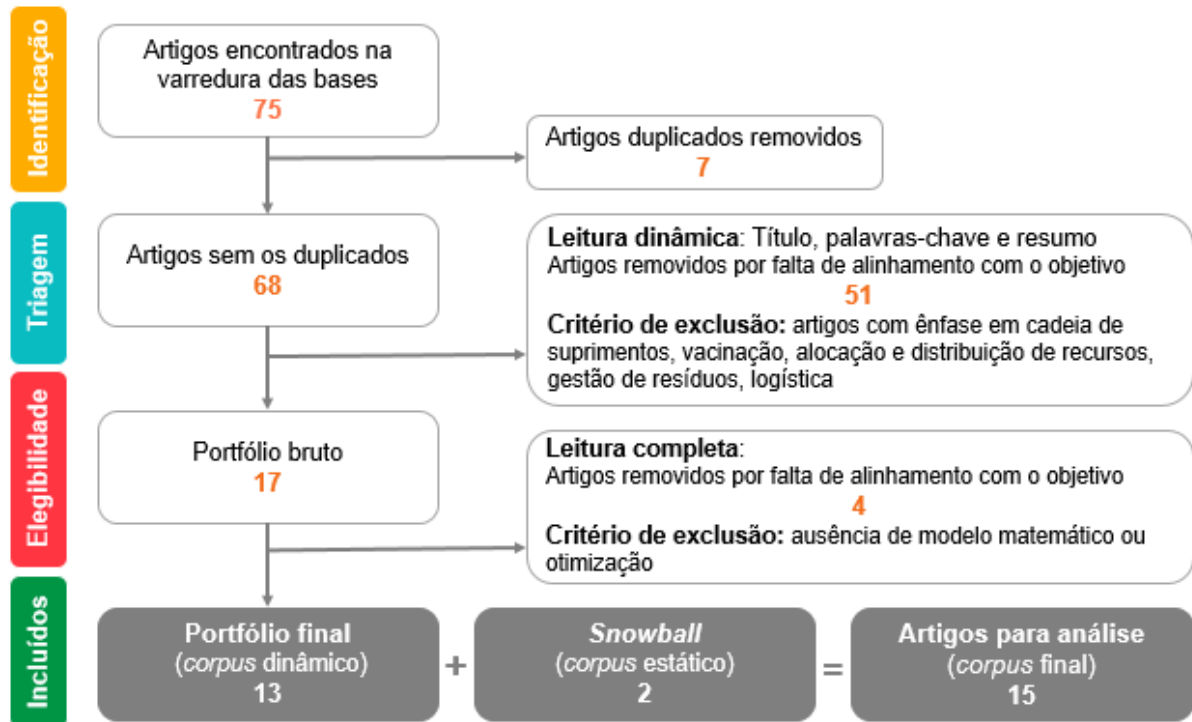
avaliar aspectos de interesse como o foco do estudo, a doença em questão, o modelo compartimental epidêmico² usado, os tipos de INF testadas, a formulação do problema (função objetivo, restrições, variáveis de decisão), a técnica de otimização e *softwares* utilizados, a escala temporal e geográfica adotada no estudo e se realizou análise de sensibilidade. A apresentação detalhada do conteúdo dos artigos considerando esses aspectos de interesse é feita na seção 2.4.

Além disso, de modo a não incluir apenas publicações recentes (últimos cinco anos), adotou-se uma abordagem de bola de neve ou *snowball*, que permite identificar artigos seminais de autores frequentemente citados na área de estudo da revisão sistemática de literatura (WOHLIN, 2014, p. 3). Realizou-se este procedimento ao longo das leituras completas dos 13 artigos selecionados, destacando as referências mais pertinentes, principalmente aquelas que foram mais citadas, além de outras incluídas como importantes. Assim, outros 2 artigos foram adicionados como *corpus* estático, resultando em um *corpus* final de análise de 15 publicações.

A Figura 3 mostra um fluxograma PRISMA que resume todo o processo descrito na revisão sistemática de literatura, da busca nas bases científicas até a seleção do portfólio final de artigos.

² Em epidemiologia, os modelos compartimentais epidêmicos dividem os membros de uma população em vários compartimentos (subgrupos) com base nos estágios de uma doença infecciosa e descrevem as taxas de movimentação de um compartimento para outro, as taxas de contato e a duração da infecção (FRAUENTHAL, 2012).

Figura 3 – Fluxograma PRISMA do processo de revisão sistemática



Fonte: Autoria própria, adaptado de Page et al. (2021).

A realização de todas as etapas da revisão sistemática de literatura possibilitou a definição do portfólio bibliográfico, que além de contribuir com o referencial teórico desta dissertação, também serviu como base para a escolha de um modelo que auxiliasse na proposição do modelo matemático. A seção 2.4 resume as publicações que constituem o portfólio bibliográfico final e que foram revisadas para este trabalho.

2.4 Conteúdo dos artigos

Barbato, Ceselli e Premoli (2022) propõem um modelo de programação linear inteira mista (PLIM) para redistribuição de recursos de saúde entre áreas carentes e superavitárias para responder ao aumento de pacientes que demandam tratamento especializado em caso de epidemias. A redistribuição inclui o reaproveitamento das enfermarias do hospital, a realocação de pacientes internados entre enfermarias, a atribuição de novos pacientes a enfermarias adequadas, a realocação da equipe e recursos médicos, a distribuição de recursos médicos provenientes de fornecedores externos e a alta seletiva de pacientes leves que passam a ser tratados em casa. Os autores buscam minimizar os custos da qualidade do serviço prestado aos pacientes

e os custos econômicos decorrentes da reorganização do sistema de saúde usando uma heurística. O modelo foi testado utilizando dados reais do início da COVID-19 na região norte da Itália.

Luo, Wan e Wang (2022) desenvolveram um modelo de PLIM de localização e alocação multiperíodo para facilitar a gestão integrada e dinâmica de suprimentos de emergência e pacientes infectados durante uma pandemia. O modelo determina a implantação de vários tipos de instalações médicas de emergência (hospitais), aloca os suprimentos médicos (máscaras cirúrgicas e roupas de proteção) e equipes (médicos e enfermeiros) para cada instalação, além de transferir vários tipos de pacientes infectados para as instalações implantadas de forma justa e eficaz, considerando a transição de seu estado de saúde entre os períodos. A função objetivo considera minimizar um custo total ponderado, o qual inclui o custo total da penalidade por pacientes não atendidos em tempo hábil e o custo total da operação. Os autores conduziram um estudo de caso para os distritos de Wuhan, na China, mais afetados pela COVID-19.

Hosseini-Motlagh, Samani e Homaei (2023) desenvolvem uma abordagem de programação estocástica *fuzzy* de multiestágios para alocar os casos de COVID-19 aos centros de saúde, sob incerteza no número de casos suspeitos. Os pacientes são categorizados em grupos distintos, de acordo com a gravidade da doença e seus antecedentes, e são encaminhados de acordo com as suas necessidades para diferentes tipos de estabelecimentos de saúde (instalações de triagem, quarentena, unidades de saúde) de modo a melhorar o desempenho do sistema de saúde. Os autores também estimaram a taxa de transmissão usando fatores como taxa de contato, duração do contato, estrutura etária da população, suscetibilidade à infecção e número de eventos de transmissão por contato. O modelo busca minimizar a taxa de transmissão da doença e as decisões são relativas à localização das instalações, a capacidade das unidades de saúde e o número de casos alocados para diferentes unidades.

Yin, Büyüktaktın e Patel (2023) constroem um modelo de PLIM estocástico de vários estágios e com aversão ao risco para estudar a alocação de ventiladores para o tratamento de pacientes graves com COVID-19. O modelo considera a incerteza de indivíduos assintomáticos não testados durante a transmissão do COVID-19 e envolve vários cenários de pandemia durante cada estágio do horizonte de planejamento. Também é incorporada a migração de curto prazo entre as regiões

altamente impactadas e taxas de transmissão variáveis são utilizadas sob várias intervenções não farmacêuticas. A função objetivo minimiza o número de infecções e óbitos considerando diferentes estratégias de intervenção, ao mesmo tempo em que determina o momento ideal e o local para alocação dos ventiladores. O modelo é calibrado, validado e testado utilizando dados reais da COVID-19 coletados durante os estágios iniciais da pandemia em condados bastante afetados de Nova York e Nova Jersey, nos Estados Unidos da América (EUA).

Büyüktaktın, des-Border e Kibiş (2018) apresentam um modelo epidêmico-logístico para ser usado no controle de uma epidemia de Ebola. O objetivo de seu modelo de PLIM é minimizar o número total de infectados e óbitos, determinando a quantidade ideal, o momento e a localização dos recursos considerando a dinâmica de propagação espacial de uma epidemia. Um determinado orçamento é destinado para a implementação de estratégias de intervenção de curto prazo visando controlar a transmissão da doença, que incluem o tratamento médico para pacientes em instalações específicas, unidades de isolamento de casos, o rastreamento de contatos e práticas seguras de sepultamento. Segundo os autores, essa modelagem pode ser adaptada para estudar outras doenças infecciosas e fornecer orientações de políticas tangíveis para o gerenciamento de epidemias em grandes escalas temporais e geográficas.

Desse modo, Liu M. *et al.* (2020) estenderam o modelo de PLIM de Büyüktaktın, des-Border e Kibiş (2018), modificando as restrições de capacidade e simultaneamente determinando quando abrir e fechar as alas hospitalares isoladas para controle de uma epidemia, de modo a minimizar a demanda total insatisfeita em todas as áreas afetadas ao longo do horizonte de planejamento considerado. O modelo foi empregado em um estudo de caso real para controlar o surto de H1N1 que ocorreu em 2009, na China.

Também, baseados no modelo de Büyüktaktın, des-Border e Kibiş (2018), Biswas e Alfandari (2022) propõem um modelo epidêmico de PLIM para determinar a melhor ordem de INF em um dado horizonte de planejamento, levando em consideração a escassez de leitos hospitalares e de médicos. Duas funções objetivo distintas são consideradas separadamente: minimização do número de indivíduos infectados e mortos. Usando dados reais da pandemia de COVID-19 na França, os autores comparam a adoção de estratégias centralizadas (decisões uniformes a nível nacional) e descentralizadas (decisões diferentes entre regiões) e avaliam a sua

eficácia no crescimento de infecções e óbitos em múltiplos cenários. Os autores ainda demonstram analiticamente que a sequência ideal de INF sempre segue um padrão de severidade decrescente, e assim simplificam o modelo para uma programação linear inteira (PLI) reduzindo o tempo computacional.

Tatapudi *et al.* (2019) usaram uma programação linear inteira mista biobjetivo para representar um modelo de regressão linear que prediz a taxa de ataque de infecção de uma pandemia de gripe, de modo a identificar as principais estratégias de INF para conter a disseminação da doença. Então, usando os resultados do modelo proposto, um novo modelo matemático é resolvido para encontrar os valores ótimos das INF selecionadas anteriormente, minimizando a taxa de ataque de infecção, um parâmetro que representa a proporção da população infectada ao final de uma pandemia.

Kaleta *et al.* (2022) desenvolvem um modelo que considera a mobilidade e a estrutura das populações regionais ao otimizar INF no longo prazo, para controlar a propagação de doenças epidêmicas. Trata-se de um modelo não linear e não convexo de larga escala, que foi resolvido com a aplicação de um algoritmo evolutivo, o CMA-ES (*Covariance Matrix Adaptation Evolution Strategy*). Foram consideradas três funções objetivo distintas, as quais minimizavam o número total de casos sintomáticos, o número máximo de casos sintomáticos para não exceder os recursos hospitalares ou o número total de mortes decorrentes da doença. O algoritmo evolutivo aplicado forneceu soluções melhores em comparação com heurísticas simples.

Nonato *et al.* (2022) propõem uma ferramenta denominada “*Robot Dance*”, que permite antecipar a evolução geográfica de doenças infecciosas e sugere níveis de intervenção para conter a sua propagação, levando em conta a mobilidade dos habitantes por meio de uma rede regional. Trata-se de um problema de otimização estocástica, formulado como um modelo de programação não linear (PNL), não convexo e quadrático. O modelo considera diferentes funções objetivo, a ser escolhida pelo usuário, que podem visar a maximização da circulação de pessoas, a minimização do número de reprodução, a minimização da duração de *lockdowns* consecutivos, entre outras, além de restrições que retratam a transmissão do patógeno, a maneira como as pessoas se movem entre as cidades para trabalhar e a capacidade hospitalar. Usando dados reais da COVID-19, várias funcionalidades do

modelo são demonstradas aplicando-o para São Paulo, o estado mais populoso do Brasil.

Scarabaggio *et al.* (2022) desenvolvem uma abordagem de controle preditivo estocástico que auxilia na seleção de estratégias não farmacológicas diversificadas para combater a disseminação da COVID-19 ao longo de um horizonte de planejamento. O problema de otimização é formulado como um modelo de programação não linear inteira mista (PNLIM), que considera a incerteza em cada parâmetro epidêmico com base em limites específicos e com taxa de infecção dada em função do nível de mobilidade em diferentes categorias socioeconômicas (varejo e recreação, locais de trabalho e transporte público). A função objetivo visa minimizar o impacto das estratégias de mitigação no quadro econômico, respeitando um limiar no número de indivíduos hospitalizados. Para avaliar a eficácia da abordagem proposta, os autores aplicaram a metodologia usando dados reais da COVID-19 para as 20 regiões italianas e um algoritmo genético foi usado para resolver o problema.

Também, a fim de reduzir os impactos econômicos e epidemiológicos da pandemia, Soltanisehat, González e Barker (2022) apresentam uma formulação de PLIM multiobjetivo que fornece uma estratégia dinâmica ideal de fechamento e reabertura de estados e setores ao longo de um horizonte de planejamento. Os autores combinam um problema de fluxo máximo de rede e um modelo compartimental epidêmico para construir o modelo proposto, que considera minimizar três objetivos simultaneamente: o impacto epidêmico em termos da porcentagem da população infectada nos estados, o impacto econômico nos negócios locais em termos da porcentagem de desemprego acarretado pelos fechamentos e o impacto econômico no comércio em termos de porcentagem da demanda total não atendida nos estados e indústrias. Usando dados reais da COVID-19, o modelo é implementado para 11 estados, incluindo o Distrito de Columbia, e 19 setores dos EUA.

Xu, Wu e Topcu (2021) propõem uma abordagem de síntese de controle para mitigação da epidemia com base em três modelos de controle distintos com vacinação, imunidade de escudo e quarentena, respectivamente. Os autores desenvolvem métodos para sintetizar estratégias de controle com base em três modelos epidêmicos específicos de COVID-19 com especificações de lógica temporal métrica (LTM). O problema de síntese é então convertido em um problema de PNLIM, especificamente em uma programação bilinear inteira mista (*mixed-integer bi-linear programming*) ou em programação fracionária inteira mista (*mixed-integer fractional*

constrained programming), e resolvido com auxílio de *solvers*. Resultados de simulação são fornecidos para três estudos de caso diferentes usando parâmetros de modelo estimados a partir de dados da Lombardia, na Itália, e de Wuhan, na China.

Também, atentando-se ao problema de prevenção de doenças e controle epidêmico após as epidemias de gripe em 2009 e 2011, Deng, Shen e Vorobeychik (2013) formulam dois modelos de programação não linear inteira para decidir quais indivíduos devem ser vacinados e que locais devem ser fechados, de modo a minimizar o número esperado de indivíduos infectados. Um dos modelos considera um comportamento compensatório (as pessoas visitarão locais alternativos se os de maior preferência estiverem fechados) e o outro não (se um local estiver fechado, os indivíduos que visitam o local ficarão em casa e não visitarão nenhum outro local). Os modelos são linearizados e a otimização é feita por meio de algoritmos baseados em estratégia gulosa, programação dinâmica e programação inteira, comparando a qualidade de solução e a eficiência computacional entre eles. Os autores testam o modelo simulando o comportamento de 100 indivíduos escolhidos aleatoriamente visitando 195 locais em Portland, EUA.

Zaric e Brandeau (2001) apresentam um modelo de alocação de recursos para o controle epidêmico no qual diferentes intervenções são consideradas. O objetivo é maximizar os Anos de Vida Ajustados pela Qualidade (QALY) ganhos ou o número de novas infecções evitadas, levando em conta uma restrição orçamentária. O modelo permite a interação de populações e funções de produção não lineares, sendo aplicável a um horizonte de tempo fixo. Os autores expõem que obter uma solução analítica pode ser difícil, então desenvolvem métodos de aproximação para as funções objetivo, além de heurísticas para resolver o problema geral de alocação de recursos. Resultados de estudos numéricos são apresentados para as aproximações e heurísticas.

O Quadro 2 apresenta um resumo sobre os artigos descritos nesta seção levando em conta os aspectos de interesse avaliados, os quais apoiaram a escolha de um modelo que possa servir como base para a formulação do modelo matemático proposto neste trabalho.

Quadro 2 – Resumo dos trabalhos descritos na revisão bibliográfica

(continua)

Referência	Doença	Modelo compartimental	Escala geográfica	Escala temporal	Tipos de INF	Formulação do problema	Otimização (software)	Objetivo	Análise de sensibilidade
Barbato, Ceselli e Premoli (2022)	COVID-19	Não contempla	Lombardia (Itália)	Primavera de 2020	Não contempla	PLIM	Algoritmo heurístico (Gurobi)	Minimização de custos	Sim
Luo, Wan e Wang (2022)	COVID-19	Não contempla	Wuhan (China)	30 dias	Não contempla	PLIM	<i>Solver</i> (CPLEX)	Minimização de custos	Sim
Hosseini-Motlagh, Samani e Homaei (2023)	COVID-19	Não contempla	Teerã (Irã)	Não específica	Isolamento (quarentena)	Programação estocástica <i>fuzzy</i> multiestágio, PLIM	<i>Solver</i> (GAMS, CPLEX)	Minimização da taxa de transmissão	Sim
Yin, Büyüktaktın e Patel (2023)	COVID-19	SIXHCRD ^a	Nova York e Nova Jersey(EUA)	10 semanas	Máscaras, distanciamento social e <i>lockdown</i>	PNLIM, PLIM estocástica	<i>Solver</i> (CPLEX)	Minimização de infecções e mortes	Sim
Büyüktaktın, des-Border e Kibiş (2018)	Ebola	SITRFB ^b	Guiné, Libéria e Serra Leoa	60 semanas	Isolamento (quarentena)	PNLIM, PLIM	<i>Solver</i> (CPLEX)	Minimização de infecções e mortes	Sim
Liu <i>et al.</i> (2020)	H1N1	SEIHRA ^c	Jiangsu (China)	180 dias	Isolamento (quarentena)	PNLIM, PLIM	<i>Solver</i> (MATLAB, CPLEX)	Minimização de demanda insatisfeita	Sim
Biswas e Alfandari (2022)	COVID-19	SIRD ^d	França	8 semanas	5 níveis: Isolamento (quarentena), restrição de viagem, fechamento de escolas, proibição de aglomerações e <i>lockdown</i>	PNLIM, PLIM	<i>Solver</i> (CPLEX)	Minimização de infecções e mortes	Sim

Quadro 2 – Resumo dos trabalhos descritos na revisão bibliográfica

(continuação)

Referência	Doença	Modelo compartimental	Escala geográfica	Escala temporal	Tipos de INF	Formulação do problema	Otimização (software)	Objetivo	Análise de sensibilidade
Tatapudi <i>et al.</i> (2019)	H1N1	Não contempla	Não específica	Não específica	Isolamento, quarentena e fechamento de escolas e locais de trabalho	PLIM biobjetivo	<i>Solver</i> (CPLEX)	Minimização de viés e número de preditores, minimização da taxa de ataque da doença	Sim
Kaleta <i>et al.</i> (2022)	COVID-19	SEAIRD ^e	Polônia	6 meses	Escala de 0 a 1	PNL (não convexa)	Estratégia evolucionária (CMA-ES)	Minimização de infecções sintomáticas e mortes	Sim
Nonato <i>et al.</i> (2022)	COVID-19	SEIR ^f	São Paulo (Brasil)	56 semanas	6 níveis: severa, alta, elevada, moderada, baixa, aberto	PNL (não convexa e quadrática)	<i>Solver</i> (IPOPT)	Maximização da circulação de pessoas, minimização no número de reprodução, minimização de <i>lockdown</i>	Sim
Scarabaggio <i>et al.</i> (2022)	COVID-19	SIRCQTHE ^g	Itália	10 semanas	5 níveis (escala de cores)	PNLIM estocástico	Algoritmo Genético (MATLAB)	Minimização de custos econômicos	Sim
Soltanisehat, González e Barker (2022)	COVID-19	SIRD	11 estados (EUA)	10 semanas	Fechado ou aberto	PNLIM multiobjetivo	método AUGMECON e o algoritmo de solução (Gurobi)	Minimização de infecções, desemprego e demanda não atendida	Sim

Quadro 2 – Resumo dos trabalhos descritos na revisão bibliográfica

Referência	Doença	Modelo compartimental	Escala geográfica	Escala temporal	Tipos de INF	Formulação do problema	Otimização (software)	Objetivo	Análise de sensibilidade
Xu, Wu e Topcu (2021)	COVID-19	SEIR e SUQC ^h	Lombardia (Itália) e Wuhan (China)	100 dias	Imunidade de escudo e quarentena	LTM, programação bilinear inteira mista, programação fracionária inteira mista	<i>Solver</i> (GEKKO)	Minimização de esforços de controle de imunidade de escudo e de quarentena	Não, mas sugere
Deng, Shen e Vorobeychik (2013)	Não específica	Não contempla	Portland, Oregon (EUA)	35 dias	Fechamento de locais	PNLIM, PLIM estocástica	Algoritmo guloso, híbrido e <i>Solver</i> (CPLEX)	Minimização de infecções	Sim
Zaric e Brandeau (2001)	Não específica	Genérico (m compartimentos), porém exemplifica com um modelo SI	Não específica	Genérico (T anos)	Genérico (n intervenções)	PNL	Métodos de aproximação e heurísticas	Maximização de QALY ganhos, maximização de infecções evitadas	Não

Nota: ^a Suscetível, infectado testado, infectado não testado assintomático, hospitalizado, UTI, recuperado, morto (SIXHCRD)

^b Suscetível, infectado, tratado, recuperado, funeral, enterrado (SITRFB)

^c Suscetível, exposto, infectado, hospitalizado, recuperado e assintomático parcialmente infeccioso (SEIHRA)

^d Suscetível, infectado, recuperado, morto (SIRD)

^e Suscetível, exposto, infectado assintomático, infectado sintomático, recuperado, morto (SEAIRD)

^f Suscetível, exposto, infectado, recuperado (SEIR)

^g Suscetível, infectado, removido, contagioso não detectado, quarentena, ameaçado, recuperado, morto (SIRCQTHE)

^h Suscetível, infectado sem quarentena, infectado em quarentena, infectado confirmado (SUQC).

Fonte: Autoria própria (2023).

A partir da revisão bibliográfica pôde-se constatar que a maior parte dos artigos analisados utilizam modelos compartimentais epidêmicos para retratar a progressão de doenças, o que segundo Dimitrov e Meyers (2010, p. 8) pode ocorrer devido à maior simplicidade e tratabilidade computacional quando comparado a modelos mais complexos como os de redes de contato e simulações baseadas em agentes.

Também foi possível verificar que diversas formulações presentes nesses estudos combinam modelos epidêmicos compartimentais de tempo discreto com modelos de alocação e distribuição de recursos médicos (BÜYÜKTAHTAKIN; DES-BORDER; KIBIŞ, 2018; LIU, M. *et al.*, 2020; YIN; BÜYÜKTAHTAKIN; PATEL, 2023) ou ainda com a alocação de INF ao longo de um horizonte de planejamento (BISWAS; ALFANDARI, 2022; NONATO *et al.*, 2022; SCARABAGGIO *et al.*, 2022; SOLTANISEHAT; GONZÁLEZ; BARKER, 2022).

Um ponto a ser destacado é que, conforme mencionado por Büyüktaktakın, des-Border e Kibiş (2018, p. 3), os modelos lineares discretos são preferíveis em relação aos modelos epidêmicos não lineares e contínuos, porque podem ser mais facilmente implementados por não-matemáticos, conferindo, assim, uma vantagem no campo da saúde pública. Assim, buscando evitar uma maior complexidade computacional decorrente de não-linearidades, alguns autores aplicaram técnicas para linearizar restrições em seus modelos (BISWAS; ALFANDARI, 2022; BÜYÜKTAHTAKIN; DES-BORDER; KIBIŞ, 2018; LIU, M. *et al.*, 2020; YIN; BÜYÜKTAHTAKIN; PATEL, 2023; ZARIC; BRANDEAU, 2001).

Desse modo, com base nas características dos estudos listados no Quadro 2 e em consonância com o que foi exposto, o modelo matemático formulado por Biswas e Alfandari (2022) mostrou-se o mais adequado para servir como base para o desenvolvimento do modelo matemático proposto neste trabalho. A escolha se deu porque ele utiliza um modelo compartimental epidêmico e é formulado por meio de PLIM, o que implica uma tendência de menor complexidade computacional em relação a modelos não lineares. Além disso, utiliza uma grande variedade de INF, que são combinadas em cinco níveis de medidas de contenção da doença, é aplicado para a COVID-19 em uma escala geográfica em nível de país, possui escala temporal adaptável e uma função objetivo que pode ser alterada aos objetivos deste trabalho.

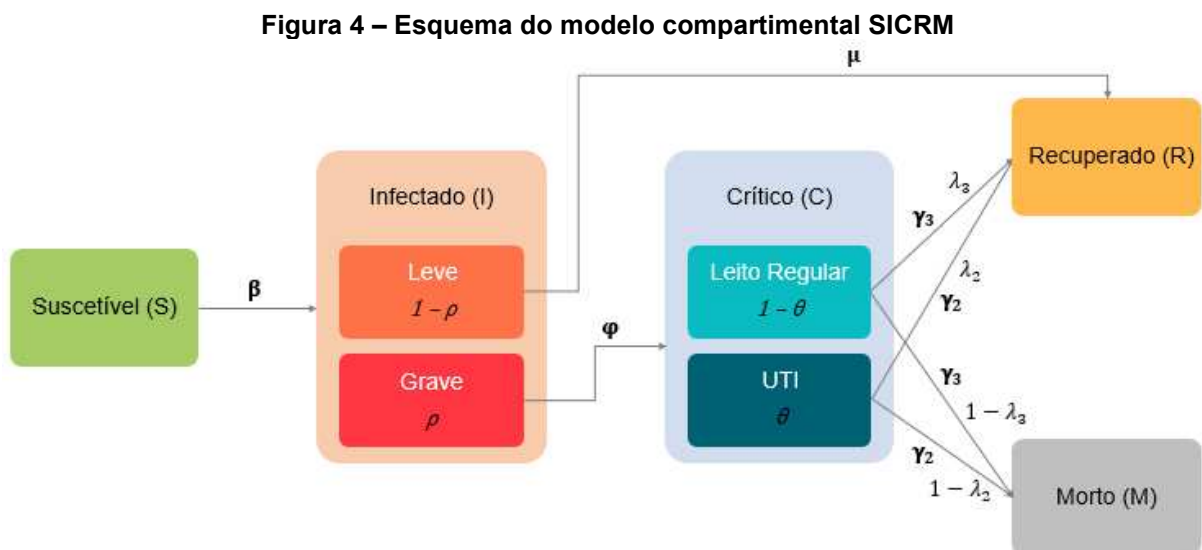
Dessa forma, o Capítulo 3 traz o modelo matemático adaptado de Biswas e Alfandari (2022) para as hipóteses deste trabalho, apresentando as hipóteses

adotadas e o seu equacionamento, com a descrição das variáveis e parâmetros utilizados e com o detalhamento da função objetivo e das restrições consideradas.

3 MODELO MATEMÁTICO

A modelagem matemática fornece ferramentas para os planejadores de saúde pública preverem a disseminação de doenças emergentes e analisarem o impacto de possíveis estratégias de intervenção (GHAMIZI *et al.*, 2020). Nesse contexto, modelos compartimentais epidêmicos, como o clássico modelo mecanicista SIR ou suas variações, têm sido amplamente utilizados (PARÉ; BECK; BAŞAR, 2020).

Neste trabalho, utilizou-se uma variação do modelo SIR, conforme ilustrado esquematicamente na Figura 4, o qual classifica os indivíduos de uma população em cinco compartimentos mutuamente exclusivos: suscetível (S), infectado (I), crítico (C), recuperado (R) e morto (M), assumindo que aqueles recuperados não se tornam suscetíveis novamente. A escolha de utilizar um modelo epidêmico simples foi motivada devido à maior quantidade de parâmetros a serem estimados nos modelos com estruturas mais complexas, o que pode resultar em uma amplificação dos erros paramétricos (GOMES; MONTEIRO; ROCHA, 2020, p. 3).



Nota: As letras gregas em *itálico* representam proporções, já as que estão em **negrito**, representam taxas de transição entre os compartimentos.

Fonte: Autoria própria, adaptado de Biswas e Alfandari (2022).

Como mostrado esquematicamente na Figura 4, os indivíduos suscetíveis podem se infectar durante interações com pessoas infectadas a uma taxa β . Os indivíduos infectados se dividem entre infecções leves (assintomáticos ou com sintomas leves) ou graves, sendo ρ a proporção de infecções graves. As infecções leves passam para o compartimento recuperado a uma taxa de μ por semana, já as

infecções graves transitam para o compartimento crítico a uma taxa de φ por semana. No compartimento crítico, o indivíduo é internado em leito regular ou em leito de UTI com base na disponibilidade, sendo θ a proporção de pacientes que requerem leitos de UTI. No compartimento crítico, os internados em leitos regulares se recuperam ou morrem a uma taxa de γ_3 , sendo λ_3 a proporção de indivíduos que se recuperam e $1 - \lambda_3$ a proporção dos que morrem. Já aqueles críticos internados em leitos de UTI se recuperam ou morrem a uma taxa de γ_2 , sendo λ_2 a proporção de indivíduos que se recuperam e $1 - \lambda_2$ a proporção daqueles que morrem. Os compartimentos recuperado e morto não possuem fluxo de saída, assim como o compartimento suscetível não possui fluxo de entrada (BISWAS; ALFANDARI, 2022).

Por se tratar de um modelo compartimental epidêmico simples e devido ao horizonte de planejamento considerado no estudo de caso ser de 13 semanas (3 meses), relativamente curto em relação à duração da epidemia, assume-se que o número total da população permanece constante, ou seja, os nascimentos e mortes naturais não são considerados (FRAUENTHAL, 2012, p. 1). Adicionalmente, esses modelos pressupõem que todo indivíduo pertencente à população está em algum compartimento em um determinado momento (PARÉ; BECK; BAŞAR, 2020).

Conforme mencionado na seção 2.4, o modelo matemático proposto neste estudo tem por base o modelo desenvolvido por Biswas e Alfandari (2022). Optou-se por manter diversas características e considerações adotadas no modelo da literatura, por julgá-las adequadas e valorosas. Dentre elas, a consideração da disponibilidade de recursos de saúde, visto que diversos outros estudos também se preocupam em avaliar a capacidade do sistema de saúde para atender os indivíduos infectados por COVID-19, de modo que ela não seja excedida quando ocorrem os picos de infecção da doença (BARBATO; CESELLI; PREMOLI, 2022; FERGUSON *et al.*, 2020; HOSSEINI-MOTLAGH; SAMANI; HOMAEI, 2023; NONATO *et al.*, 2022; SCARABAGGIO *et al.*, 2022).

De maneira semelhante a Biswas e Alfandari (2022), neste modelo também foi avaliada a escassez de três recursos de saúde (médicos, leitos de Unidade de Terapia Intensiva (UTI) e leitos regulares) e qual o impacto nas variáveis estado epidêmico, as quais representam os compartimentos do modelo epidêmico. Considerou-se que a falta de leitos regulares e de médicos adia o processo de recuperação mantendo o indivíduo no estado crítico e a escassez de leitos de UTI leva o indivíduo à morte.

Além da situação epidêmica, essa escassez de recursos também impacta no nível de INF a ser escolhida pelo formulador de políticas posteriormente. A severidade dessas medidas afeta a taxa de infecção β e ajuda a controlar a disseminação do vírus.

O Quadro 3 traz um resumo das diferentes INF que foram consideradas neste trabalho. Essas medidas foram combinadas para representar cinco diferentes níveis de INF, com severidade de restrição crescente, que podem ser sugeridos pelo modelo matemático aos tomadores de decisão (BISWAS; ALFANDARI, 2022).

Quadro 3 – Intervenções não farmacêuticas

INF	Descrição	Nível 1	Nível 2	Nível 3	Nível 4	Nível 5
Autoisolamento	Isolamento ou quarentena de indivíduos vulneráveis e sintomáticos por 1 semana	x	x	x	x	x
Fechamento de escolas	Fechamento de escolas e universidades		x	x	x	x
Restrições de viagem	Restrições de viagem dentro e entre regiões com base na distância.			x	x	x
Proibição de reunião pública	Restrição de aglomerações para eventos públicos acima de 50 pessoas				x	x
<i>Lockdown</i>	Fechamento total do serviço, toque de recolher, restrição em massa de movimento					x

Fonte: Autoria própria, traduzido e adaptado de Biswas e Alfandari (2022).

De acordo com o Quadro 3, o nível 1 corresponde ao autoisolamento de indivíduos infectados. Já o nível 2 compreende, além do autoisolamento, o fechamento de todas as instituições de ensino. O nível 3 acrescenta restrições de viagem às medidas adotadas no nível 2. O nível 4 mantém as demais restrições do nível 3 e adiciona a proibição de aglomeração de pessoas em eventos públicos. Por fim, o nível 5 mantém as demais restrições dos níveis anteriores e introduz o *lockdown*.

No entanto, conforme mencionado por Hulíková Tesárková e Dzúrová (2022), ao avaliar intervenções de saúde pública, é mais adequado usar métricas de mortalidade que também levam em consideração a prematuridade das mortes, como por exemplo, Anos de Vida Perdidos (AVP). Essa medida é usada para ajudar a quantificar a perda social e econômica devido à morte prematura (GARDNER; SANBORN, 1990).

Diversas publicações abordam a estimativa de AVP no contexto da pandemia de COVID-19 (MITRA *et al.*, 2020; PIFARRÉ I AROLAS *et al.*, 2021; QUAST *et al.*, 2022; HULÍKOVÁ TESÁRKOVÁ; DZÚROVÁ, 2022; GÖKLER; METINTAŞ, 2022; UGARTE *et al.*, 2022). Então, ao invés de minimizar o total de infecções ou de mortes, como feito em vários artigos apresentados na revisão de literatura na seção 2.4, tal métrica foi utilizada para quantificar os efeitos da COVID-19 no presente modelo.

Ademais, algumas outras hipóteses presentes em Biswas e Alfandari (2022), também foram adotadas, entre as quais:

- Quando um indivíduo passa para o estado crítico e precisa de internação, ele só tem acesso a um dos dois tipos de leitos: leito regular ou leito de UTI;
- Apenas as infecções que necessitam de internação são consideradas para o cálculo dos óbitos, de maneira semelhante ao que foi adotado também em Candel *et al.* (2021).

3.1 Definição dos parâmetros e variáveis

Antes de apresentar o modelo de otimização, os conjuntos e a notação dos parâmetros e variáveis de decisão utilizados no modelo são descritos. O Quadro 4 descreve os índices e conjuntos que são utilizados.

Quadro 4 – Lista de índices e conjuntos do modelo

Índice	Conjunto	Descrição
$t \in T$	$T = \{1, \dots, maxT\}$	Período de tempo (em semanas); $maxT$ indica o número máximo de semanas consideradas
$i \in N$	$N = \{1, 2, 3, 4, 5\}$	Níveis de INF
$k \in K$	$K = \{1, \dots, maxK\}$	Unidades da federação (UF); $maxK$ indica o número total de UF consideradas
$r \in Rec$	$Rec = \{1, 2, 3\}$	Recursos médicos (1 = médico; 2 = leito de UTI; 3 = leito regular)

Fonte: Autoria própria (2023).

Os parâmetros epidêmicos e outros parâmetros utilizados no modelo são listados no Quadro 5.

Quadro 5 – Lista de parâmetros do modelo

(continua)

Parâmetro	Descrição
β	Taxa de transmissão semanal por pessoa

Quadro 5 – Lista de parâmetros do modelo

(conclusão)

Parâmetro	Descrição
φ	Taxa semanal em que um indivíduo infectado entra no estado crítico
μ	Taxa semanal na qual uma infecção não grave se recupera
γ_2	Taxa semanal em que uma infecção crítica deixa a UTI
γ_3	Taxa semanal em que uma infecção crítica deixa o leito regular
ρ	Proporção de infectados que se tornam críticos (precisam de hospitalização)
θ	Proporção de indivíduos críticos que necessitam de leitos de UTI
λ_2	Proporção de indivíduos hospitalizados em leitos de UTI que se recuperam
λ_3	Proporção de indivíduos hospitalizados em leitos regulares que se recuperam
ϵ	Proporção de indivíduos críticos que se autoisolam
S_{k1}	Número inicial de indivíduos suscetíveis na UF k , $\forall k \in K$
I_{k1}	Número inicial de indivíduos infectados na UF k , $\forall k \in K$
C_{k1}	Número inicial de indivíduos críticos na UF k , $\forall k \in K$
R_{k1}	Número inicial de indivíduos recuperados na UF k , $\forall k \in K$
M_{k1}	Número inicial de indivíduos mortos na UF k , $\forall k \in K$
H_{k1}	Número inicial de médicos ativos na UF k , $\forall k \in K$
α_i	Redução na taxa de transmissão por nível i de INF, $\forall i \in N$
$\bar{\alpha}$	Redução máxima na taxa de transmissão, $\bar{\alpha} = \text{Max}\{\alpha_i \mid i \in N\}$
w_i	Peso atribuído a cada nível de INF i , $\forall i \in N$
l_{2k}	Número de leitos de UTI ($r = 2$) na UF k , $\forall k \in K$
l_{3k}	Número de leitos regulares ($r = 3$) na UF k , $\forall k \in K$
η_{rk}	Proporção do recurso r alocado para casos não-COVID na UF k , $\forall r \in \text{Rec}$, $\forall k \in K$
m	Número de pacientes atendidos por um médico
$\bar{\tau}$	Tempo médio, em semanas, de quarentena para médicos após serem infectados
P	População total do país
p_k	População da UF k , $\forall k \in K$
$AVP_{\text{médio } k}$	Anos de Vida Perdidos médio por UF k , $\forall k \in K$
b, c	Parâmetros de modelo de Norris (2006) para estimar a expectativa de vida a partir do PIB <i>per capita</i>
PIB_{0k}	Produto Interno Bruto inicial para a UF k , $\forall k \in K$
ΔPIB_{ki}	Varição no Produto Interno Bruto por UF k e por nível de INF i , $\forall k \in K$, $\forall i \in N$
V_{kt}	Limite inferior teórico de infecções para o período t e UF k , $\forall t \in T$, $\forall k \in K$
I_{max}	Limite superior teórico de indivíduos infectados para todos os períodos

Fonte: Autoria própria (2023).

Assumiu-se que os parâmetros epidêmicos (taxas e proporções) não mudam ao longo do horizonte de planejamento de 13 semanas adotado no modelo, devido ao

fato de o governo ter de divulgar um plano de INF ao longo de várias semanas e não poder alterá-lo de maneira repentina, permitindo que as pessoas e as organizações consigam planejar as suas agendas e operações (BISWAS; ALFANDARI, 2022).

As variáveis de decisão usadas no modelo encontram-se sumarizadas no Quadro 6.

Quadro 6 – Lista de variáveis do modelo

Variável	Domínio	Descrição
x_{kit}	$\{0, 1\}$	= 1 se nível de INF i é selecionado para semana t e UF k , caso contrário 0
S_{kt}	\mathbb{R}_+	Número de indivíduos suscetíveis na semana t na UF k
I_{kt}	\mathbb{R}_+	Número de indivíduos infectados na semana t na UF k
C_{kt}	\mathbb{R}_+	Número de indivíduos críticos na semana t na UF k
R_{kt}	\mathbb{R}_+	Número de indivíduos recuperados na semana t na UF k
M_{kt}	\mathbb{R}_+	Número de indivíduos mortos na semana t na UF k
H_{kt}	\mathbb{R}_+	Número de médicos ativos na semana t na UF k
s_{rkt}	\mathbb{R}_+	Número de unidades do recurso r em escassez na semana t na UF k
z_{rkt}	$\{0, 1\}$	= 1 se a demanda do recurso r excede a oferta na semana t na UF k , 0 caso contrário
Q_{rkt}	\mathbb{R}_+	Mínimo entre o número de indivíduos que precisam (demanda) e realmente utilizam (capacidade) o recurso r na semana t na UF k
z_{0kt}	$\{0, 1\}$	= 1 se o número de indivíduos não tratados por falta de médicos for menor que o número de indivíduos não tratados por falta de leitos regulares na semana t na UF k , 0 caso contrário
Q_{0kt}	\mathbb{R}_+	Máximo entre o número de indivíduos não tratados por falta de médicos e leitos regulares na semana t na UF k
X_{kt}	\mathbb{R}_+	Substituição de $(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt}$
Y_{0kt}	\mathbb{R}_+	Substituição de $H_{kt}z_{1kt}$
Y_{rkt}	\mathbb{R}_+	Substituição de $C_{kt}z_{rkt}$
U_{rkt}	\mathbb{R}_+	Substituição de $s_{rkt}z_{0kt}$
W_{kit}	$\{0, 1\}$	= 1 se o nível de INF i não for selecionado na semana $t - 1$ e for selecionado na semana t na UF k , 0 caso contrário

Fonte: Autoria própria (2023).

Destaca-se que x_{kit} é a principal variável de decisão, que define qual o nível de INF é adotado em cada UF k a cada período de tempo t .

3.2 Função objetivo

A função objetivo, apresentada na Equação (1), visa minimizar os Anos de Vida Perdidos em todas as unidades da federação k e ao longo de todo o horizonte de planejamento T .

$$\begin{aligned} \text{Minimize } z = & \sum_{k=1}^{|K|} \sum_{t=1}^{|T|} ((1 - \lambda_2)\gamma_2 Q_{2kt} + (1 - \lambda_3)\gamma_3 Q_{3kt} + s_{2kt}) AVP_{\text{médio } k} \\ & + \sum_{k=1}^{|K|} \sum_{i \in N} \sum_{t=1}^{|T|} \left(-b p_k^{c+1} (PIB_{0k}^{-c} - (PIB_{0k} + \Delta PIB_{ki})^{-c}) \right) x_{kit} \end{aligned} \quad (1)$$

A função objetivo é composta por duas partes. A primeira parte considera os Anos de Vida Perdidos (AVP) em decorrência dos óbitos diretos devido à pandemia de COVID-19. Os óbitos são contabilizados apenas para os indivíduos em estado crítico e que se encontram hospitalizados em leitos regulares ou de UTI, além daqueles que morrem devido à escassez de leitos de UTI, os quais são multiplicados pelos Anos de Vida Perdidos médio para cada UF k em decorrência da doença.

Já a segunda parte considera os Anos de Vida Perdidos (AVP) em decorrência das variações econômicas no Produto Interno Bruto (PIB), conforme modelo proposto por Norris (2006, p. 100). Neste trabalho, atribuíram-se as variações no PIB das UF k às decisões indicadas pelas variáveis x_{kit} , que definem qual o nível i de INF a ser adotado.

Ressalta-se que a referida função objetivo difere da apresentada por Biswas e Alfandari (2022), buscando minorar de modo conjunto o impacto sanitário e econômico da pandemia por meio de uma mesma métrica. Assim, na modelagem da Equação (1) optou-se em não realizar normalizações ou ponderações. Foi realizada uma concepção de modelagem de modo que tanto a parte 1 da função objetivo quanto a parte 2 fornecem valores em AVP, ainda que os valores numéricos sejam oriundos de contextos distintos (social e econômico, respectivamente).

3.3 Restrições

As restrições do modelo matemático são compostas por restrições base, apresentadas na subseção 3.3.1 (cenário base), e por restrições adicionais, as quais levam em conta: (1) questões relativas à viabilidade operacional de gestão (cenário 1); (2) questões relativas à capacidade de leitos de UTI (cenário 2). Em caso de avaliação de diferentes cenários, incluem-se restrições adicionais conforme apresentado nas subseções 3.3.2 e 3.3.3.

3.3.1 Cenário base

A restrição (2) estabelece que apenas um nível de INF deve ser selecionado em cada UF k a cada semana t .

$$\sum_{i \in N} x_{kit} = 1 \quad \forall t \in T, \quad \forall k \in K \quad (2)$$

Com base no que foi demonstrado analiticamente por Biswas e Alfandari (2022, p. 1381) em seu modelo, a sequência ótima de INF sempre é ordenada da maior severidade para a menor. Desse modo, adicionou-se a restrição (3), a qual indica que as decisões relacionadas às INF sempre devem ocorrer em níveis de severidade decrescentes.

$$\sum_{i \in N} x_{kit-1} w_i \geq \sum_{i \in N} x_{kit} w_i \quad \forall t \in \{2, \dots, |T|\}, \quad \forall k \in K \quad (3)$$

A restrição (4) indica se há escassez de médicos ($r = 1$) na UF k e no tempo t , calculando a diferença entre a demanda e a oferta do recurso. A demanda por médicos é dada pela razão entre o número de indivíduos em estado crítico e o número médio de pacientes que um médico consegue atender. Já a oferta é dada pela proporção de médicos ativos no momento dedicados a tratar casos de COVID-19. Uma variável binária auxiliar z_{1kt} é inserida para garantir a correta indicação de escassez. Se a variável binária z_{1kt} assumir o valor 1, a demanda supera a oferta e

há escassez do recurso. Caso contrário, a oferta é maior que a demanda e não há escassez.

$$s_{1kt} = \frac{C_{kt}z_{1kt}}{m} - (1 - \eta_{1k})H_{kt}z_{1kt} \quad \forall t \in T, \quad \forall k \in K \quad (4)$$

A restrição (5) determina a escassez de leitos de UTI ($r = 2$) na região k e no tempo t , por meio da diferença entre a demanda e a oferta do recurso. A demanda é dada pela proporção de pacientes em estado crítico que necessitam de leitos de UTI e a oferta é dada pela proporção de leitos de UTI alocados para o tratamento de casos de COVID-19. Uma variável binária, z_{2kt} , é inserida para auxiliar na correta indicação de escassez. Se a variável binária z_{2kt} assumir o valor 1, a demanda supera a oferta e há escassez de leitos de UTI. Caso contrário, não há escassez.

$$s_{2kt} = \theta C_{kt}z_{2kt} - (1 - \eta_{2k})l_{2k}z_{2kt} \quad \forall t \in T, \quad \forall k \in K \quad (5)$$

De forma semelhante às restrições (4) e (5), a restrição (6) indica a escassez de leitos regulares ($r = 3$) na região k e no tempo t , por meio da diferença entre a demanda e a oferta do recurso. A demanda é dada pela proporção de pacientes em estado crítico que necessitam de leitos regulares e a oferta é dada pela proporção de leitos regulares alocados para o tratamento de casos de COVID-19. Uma variável binária, z_{3kt} , é inserida para auxiliar na correta indicação de escassez. Se a variável binária z_{3kt} assumir o valor 1, a demanda supera a oferta e há escassez de leitos regulares. Caso contrário, não há escassez.

$$s_{3kt} = (1 - \theta)C_{kt}z_{3kt} - (1 - \eta_{3k})l_{3k}z_{3kt} \quad \forall t \in T, \quad \forall k \in K \quad (6)$$

Para garantir que as variáveis binárias z_{rkt} realmente indiquem se há escassez do recurso r , foram adicionadas variáveis contínuas Q_{rkt} , que são definidas como o mínimo entre a oferta e a demanda do recurso r . Um conjunto contendo três restrições adicionais foi inserido para cada recurso r .

O conjunto de restrições (7), (8) e (9) refere-se ao recurso médicos ($r = 1$). A restrição (7) faz com que Q_{1kt} seja igual a oferta de médicos (se $z_{1kt} = 1$) ou a demanda por médicos (se $z_{1kt} = 0$).

$$Q_{1kt} = (1 - \eta_{1k})H_{kt}z_{1kt} + \frac{C_{kt}(1-z_{1kt})}{m} \quad \forall t \in T, \quad \forall k \in K \quad (7)$$

A fim de exigir que a variável auxiliar Q_{1kt} realmente escolha o mínimo entre a oferta e a demanda de médicos, as restrições (8) e (9) são adicionadas. A restrição (8) impõe que a variável auxiliar Q_{1kt} seja menor ou igual a oferta de médicos.

$$Q_{1kt} \leq (1 - \eta_{1k})H_{kt} \quad \forall t \in T, \quad \forall k \in K \quad (8)$$

E a restrição (9) impõe que Q_{1kt} seja menor ou igual a demanda por médicos.

$$Q_{1kt} \leq \frac{C_{kt}}{m} \quad \forall t \in T, \quad \forall k \in K \quad (9)$$

O conjunto de restrições (10), (11) e (12) refere-se ao recurso leitos de UTI ($r = 2$). A restrição (10) faz com que Q_{2kt} seja igual a oferta de leitos de UTI (se $z_{2kt} = 1$) ou a demanda por UTI (se $z_{2kt} = 0$).

$$Q_{2kt} = (1 - \eta_{2k})l_{2k}z_{2kt} + \theta C_{kt}(1 - z_{2kt}) \quad \forall t \in T, \quad \forall k \in K \quad (10)$$

A restrição (11) estabelece que a variável auxiliar Q_{2kt} seja menor ou igual a oferta de leitos de UTI.

$$Q_{2kt} \leq (1 - \eta_{2k})l_{2k} \quad \forall t \in T, \quad \forall k \in K \quad (11)$$

A restrição (12) estabelece que a variável Q_{2kt} seja menor ou igual a demanda por leitos de UTI.

$$Q_{2kt} \leq \theta C_{kt} \quad \forall t \in T, \quad \forall k \in K \quad (12)$$

Já o conjunto de restrições (13), (14) e (15) refere-se ao recurso leitos regulares ($r = 3$). A restrição (13) faz com que Q_{3kt} seja igual a oferta de leitos regulares (se $z_{3kt} = 1$) ou a demanda por esse tipo de leito (se $z_{3kt} = 0$).

$$Q_{3kt} = (1 - \eta_{3k})l_{3k}z_{3kt} + (1 - \theta)C_{kt}(1 - z_{3kt}) \quad \forall t \in T, \quad \forall k \in K \quad (13)$$

A restrição (14) impõe que a variável auxiliar Q_{3kt} seja menor ou igual a oferta de leitos regulares.

$$Q_{3kt} \leq (1 - \eta_{3k})l_{3k} \quad \forall t \in T, \quad \forall k \in K \quad (14)$$

A restrição (15) impõe que a variável Q_{3kt} seja menor ou igual a demanda por leitos regulares.

$$Q_{3kt} \leq (1 - \theta)C_{kt} \quad \forall t \in T, \quad \forall k \in K \quad (15)$$

De maneira semelhante aos três conjuntos de restrições apresentados nas equações (7) a (9), (10) a (12) e (13) a (15), o conjunto de restrições (16), (17) e (18) calcula o máximo entre o número de indivíduos que não conseguem tratamento devido à escassez de médicos e de leitos regulares. Utiliza-se o valor máximo entre os dois, em vez de somá-los, porque a escassez causada pela falta de qualquer um desses recursos resulta em pacientes não tratados, que terão sua recuperação adiada.

A restrição (16) faz com que Q_{0kt} seja igual ao número de pacientes não tratados por falta de médicos (se $z_{0kt} = 0$) ou ao número de pacientes não tratados por falta de leitos regulares (se $z_{0kt} = 1$).

$$Q_{0kt} = ms_{1kt}(1 - z_{0kt}) + s_{3kt}z_{0kt} \quad \forall t \in T, \quad \forall k \in K \quad (16)$$

A fim de impor que a variável auxiliar Q_{0kt} realmente escolha o máximo número de indivíduos que não recebem atendimento por conta da escassez de médicos e de leitos regulares, as restrições (17) e (18) são adicionadas. A restrição (17) requer que a variável auxiliar Q_{0kt} seja maior ou igual à quantidade de pacientes não atendidos devido à escassez de médicos.

$$Q_{0kt} \geq ms_{1kt} \quad \forall t \in T, \quad \forall k \in K \quad (17)$$

A restrição (18) determina que a variável auxiliar Q_{0kt} seja maior ou igual à escassez de leitos regulares.

$$Q_{0kt} \geq s_{3kt} \quad \forall t \in T, \quad \forall k \in K \quad (18)$$

De acordo com a Equação (19), o número de infectados ao final do período $t + 1$ é igual ao número de infectados no período anterior t , mais os indivíduos recém-infectados, menos os indivíduos que se tornam críticos e menos os indivíduos com infecções leves que se recuperam.

$$I_{k,t+1} = I_{kt} + \sum_{i \in N} \beta(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt} - \rho\phi I_{kt} - (1 - \rho)\mu I_{kt} \\ \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (19)$$

Um fator α_i reduz as novas infecções de acordo com o nível de INF designado (x_{kit}) para o tempo t e UF k . Conforme apresentado no Quadro 3, o autoisolamento é uma prática comum em todos os níveis de INF, sendo denotado por uma proporção ϵ de pessoas infectadas com sintomas graves que se autoisola.

A Equação (20) representa o número total de indivíduos em estado crítico ao final do período $t + 1$, que é igual aos indivíduos em estado crítico no período t , mais os indivíduos infectados que se tornam críticos e são aceitos para tratamento em hospitais com base na disponibilidade de leitos, menos os indivíduos que se recuperam ou morrem enquanto recebem tratamento, mais o máximo entre indivíduos que permanecem sem tratamento por falta de médicos ou leitos regulares e que tem a sua recuperação prolongada ($\gamma_3 Q_{0kt}$), menos os indivíduos que morrem por causa da escassez de leitos de UTI, menos os indivíduos vítimas da escassez de leitos regulares que conseguem se recuperar.

$$C_{k,t+1} = C_{kt} + \rho\phi I_{kt} - \lambda_2\gamma_2 Q_{2kt} - \lambda_3\gamma_3 Q_{3kt} - (1 - \lambda_2)\gamma_2 Q_{2kt} - (1 - \lambda_3)\gamma_3 Q_{3kt} + \gamma_3 Q_{0kt} \\ - s_{2kt} - \gamma_3 s_{3kt} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (20)$$

A restrição (21) representa o número total de médicos ativos ao final do período $t + 1$ e foi dividida em duas restrições, (21a) e (21b), de modo a não gerar uma inconsistência no índice de tempo t . A Equação (21a) calcula o número de

médicos ativos para o período $t = 2$, que é igual ao número de médicos ativos menos os médicos que se infectam no período $t = 1$. Para os demais períodos, utiliza-se a Equação (21b), que é igual ao número de médicos ativos no período anterior t , menos os médicos recém-infectados, somados aos médicos que se recuperam e retornam às suas atividades de trabalho após um tempo de quarentena $\bar{\tau}$.

$$H_{k\ t+1} = H_{kt} - \beta(Q_{2kt} + Q_{3kt}) \quad \forall t \in \{1\}, \quad \forall k \in K \quad (21a)$$

$$H_{k\ t+1} = H_{kt} - \beta(Q_{2kt} + Q_{3kt}) + \beta(Q_{2k\ t-1} + Q_{3k\ t-1}) \left(\frac{1 - \rho + \rho\theta\lambda_2\gamma_2 + \rho(1 - \theta)\lambda_3\gamma_3}{\bar{\tau}} \right) \\ \forall t \in \{2, \dots, |T| - 1\}, \quad \forall k \in K \quad (21b)$$

Considerou-se que as infecções médicas são diretamente impactadas pelo número de internações em leitos regulares e de UTI, capturadas pelas variáveis Q_{2kt} e Q_{3kt} , além do número de pacientes atendidos por um médico, m . O número de médicos recuperados do último período é adicionado ao nível de médicos disponíveis do período atual, proporcionalmente à taxa efetiva de recuperação $\left(\frac{1 - \rho + \rho\theta\lambda_2\gamma_2 + \rho(1 - \theta)\lambda_3\gamma_3}{\bar{\tau}} \right)$.

A Equação (22) calcula o número de indivíduos suscetíveis ao final do período $t + 1$, que é igual ao número de indivíduos suscetíveis no período anterior, menos os indivíduos recém-infectados no período t .

$$S_{k\ t+1} = S_{kt} - \sum_{i \in N} \beta(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (22)$$

A Equação (23) fornece o número cumulativo de indivíduos que se recuperam com ou sem tratamento. O total de recuperados ao final do período $t + 1$ é igual aos indivíduos recuperados no período anterior, mais os indivíduos críticos que se encontram hospitalizados que se recuperam, mais os infectados com sintomas leves e não hospitalizados que se recuperam, menos os indivíduos que tem a sua recuperação adiada pela falta de médicos ou leitos regulares, mais os indivíduos vítimas da escassez de leitos regulares que conseguem se recuperar.

$$R_{k\ t+1} = R_{kt} + \lambda_2 \gamma_2 Q_{2kt} + \lambda_3 \gamma_3 Q_{3kt} + (1 - \rho) \mu I_{kt} - \gamma_3 Q_{0kt} + \gamma_3 S_{3kt} \\ \forall t \in T \setminus \{T\}, \quad \forall k \in K \quad (23)$$

A Equação (24) representa o número total de indivíduos mortos ao final do período $t + 1$, que é igual ao número de indivíduos mortos no período anterior, mais as novas mortes daqueles que estavam internados em leitos regulares ou de UTI, mais os indivíduos que morrem devido à falta de leitos de UTI.

$$M_{k\ t+1} = M_{kt} + (1 - \lambda_2) \gamma_2 Q_{2kt} + (1 - \lambda_3) \gamma_3 Q_{3kt} + s_{2kt} \\ \forall t \in T \setminus \{T\}, \quad \forall k \in K \quad (24)$$

As restrições (25), (26), (27) e (28) determinam os domínios de cada conjunto de variáveis.

$$x_{kit} \in \{0,1\} \quad \forall k \in K, \quad \forall i \in N, \quad \forall t \in T \quad (25)$$

$$z_{0kt}, z_{rkt} \in \{0,1\} \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in Rec \quad (26)$$

$$S_{kt}, I_{kt}, C_{kt}, R_{kt}, M_{kt}, H_{kt} \geq 0 \quad \forall k \in K, \quad \forall t \in T \quad (27)$$

$$s_{rkt}, Q_{0kt}, Q_{rkt} \geq 0 \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in Rec \quad (28)$$

A Equação (29), é calculada após executar o modelo (pós-processamento do resultado obtido) e fornece o número total de pacientes que se encontram hospitalizados em leitos de UTI e leitos regulares em cada período t e para cada UF k .

$$C'_{kt} = Q_{2kt} + Q_{3kt} \quad \forall t \in T, \quad \forall k \in K \quad (29)$$

Destaca-se que o número de indivíduos críticos (C_{kt}) pode ser diferente do número de indivíduos que estão hospitalizados (C'_{kt}), em caso de escassez de leitos e de médicos.

Definiram-se restrições adicionais ao modelo matemático apresentado nesta subseção, de modo a avaliar diferentes cenários. Aditivamente ao cenário base, foram avaliados outros dois cenários.

3.3.2 Cenário 1: viabilidade de gestão

O cenário 1 estabelece um tempo mínimo entre as trocas de níveis de INF, fazendo com que o nível de INF selecionado fique vigente por ao menos duas semanas. Isso se justifica, pois, além de evitar alterações muito bruscas que podem confundir as pessoas e prejudicar as atividades de organizações, segundo mencionado por Antunes *et al.* (2020) há indicações de que a efetividade das medidas de controle começa entre 8 e 11 dias após a sua implantação.

Deste modo, definiram-se as restrições (30a) e (30b) que captam as trocas de nível de INF por meio de uma variável binária W_{kit} . Se a variável binária W_{kit} assumir o valor 1, o nível de INF i não estava ativo na semana $t - 1$ e foi selecionado na semana t na UF k . Caso contrário, não houve alteração.

$$x_{kit} + \sum_{j \in N \setminus \{i\}} x_{kjt-1} \geq 2W_{kit} \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in \{2, \dots, |T|\} \quad (30a)$$

$$x_{kit} + \sum_{j \in N \setminus \{i\}} x_{kjt-1} - W_{kit} \leq 1 \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in \{2, \dots, |T|\} \quad (30b)$$

Já a restrição (31) assegura que o nível de INF selecionado deve permanecer ativo por pelo menos duas semanas consecutivas na UF k .

$$x_{kit+1} \geq W_{kit} \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in T \setminus \{|T|\} \quad (31)$$

A restrição (32) garante que nenhuma troca de nível de INF seja feita da semana 1 para a semana 2.

$$x_{kit+1} = x_{kit} \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in \{1\} \quad (32)$$

A restrição (33) determina o domínio do novo conjunto de variáveis W_{kit} inserido.

$$W_{kit} \in \{0,1\} \quad \forall k \in K, \quad \forall i \in N, \quad \forall t \in T \quad (33)$$

3.3.3 Cenário 2: capacidade de leitos de UTI

Como neste modelo adotou-se a hipótese de que a escassez de leitos de UTI leva o indivíduo à morte, é apropriado considerar um *buffer* para este recurso crítico. Desse modo, o cenário 2 estabelece que a taxa de ocupação de leitos de UTI³ não deve exceder um determinado percentual de sua capacidade, para evitar que nas semanas seguintes ao final do horizonte de planejamento os leitos fiquem extremamente sobrecarregados, além de preservar os profissionais da saúde de uma sobrecarga física e mental e evitar um excesso de mortalidade devido à falta de assistência de saúde.

Além disso, existe um projeto de lei (PL 2.033/2020) que se encontra em tramitação no Senado Federal, no qual o estado pode ser responsabilizado por mortes ocorridas devido à falta de leitos de UTI no período de emergência de saúde pública de importância nacional e internacional decorrente da COVID-19 e ser obrigado a pagar indenizações e pensões aos familiares das vítimas (BRASIL, 2020f).

Assim, a restrição (34) determina que a demanda por leitos de UTI não deve ultrapassar sua capacidade em 85%. Decidiu-se adotar o valor de 85% como referência neste cenário com base em Fiocruz (2021, p. 5), porém é importante destacar que o modelo é flexível para receber o parâmetro numérico que o tomador de decisão definir, considerando o contexto específico e a política governamental que se deseja instituir. Dessa forma, o valor escolhido pode ser facilmente modificado para atender às necessidades e objetivos estabelecidos.

$$\theta C_{kt} \leq 0,85 (1 - \eta_{2k}) l_{2k} \quad \forall k \in K, \quad \forall t \in T \quad (34)$$

A formulação apresentada por meio das Equações de (1) a (28) é de um modelo de programação não linear inteira mista (PNLIM), devido aos termos

³ As taxas de ocupação de leitos de UTI para COVID-19 são frequentemente utilizadas como indicadores para avaliar a criticidade da pandemia e auxiliar no processo decisório de estados e municípios. A Fundação Oswaldo Cruz (Fiocruz), por exemplo, classificou as regiões com indicadores iguais ou superiores a 80% como zonas de alerta crítico (FIOCRUZ, 2022). Além disso, de acordo com a condição epidemiológica e a capacidade de atendimento de cada região, que devem ser avaliadas semanalmente com base em critérios técnicos, a Fiocruz também defendeu a necessidade de adotar restrições mais rígidas às atividades não essenciais, incluindo o nível máximo de restrição em áreas onde a ocupação de leitos ultrapasse 85% (FIOCRUZ, 2021, p. 5).

quadráticos que aparecem nas Equações (4), (5), (6), (7), (10), (13) e (16) relacionados à escassez de recursos de saúde e nas Equações (19) e (22), na parcela que representa os novos indivíduos infectados. O modelo de PNLIM foi linearizado e transformado em um modelo de PLIM, conforme detalhado na seção 3.4.

3.4 Linearização do modelo

Uma formulação de PLIM equivalente foi obtida substituindo os termos quadráticos, os quais são produtos entre variáveis contínuas e variáveis binárias, por novas variáveis auxiliares, de maneira semelhante ao implementado em alguns estudos (BISWAS; ALFANDARI, 2022; BÜYÜKTAHTAKIN; DES-BORDER; KIBIŞ, 2018; LIU, M. *et al.*, 2020; YIN; BÜYÜKTAHTAKIN; PATEL, 2023).

- **Linearização de $(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt} = X_{kit}$**

Uma variável auxiliar X_{kit} foi definida para substituir o seguinte termo $(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt}$, o qual possui um produto entre duas variáveis, $x_{kit}I_{kt}$. Assim, definiu-se que $I_{LI} \leq (1 - \alpha_i)(1 - \rho\epsilon)I_{kt} \leq I_{LS}$, em que I_{LI} é o limite inferior e I_{LS} é o limite superior para o número de infecções I_{kt} . De modo a garantir que X_{kit} seja realmente igual a $(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt}$, as restrições (35) a (38) foram adicionadas ao modelo.

$$X_{kit} \geq (1 - \alpha_i)(1 - \rho\epsilon)I_{LI}x_{kit} \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in T \quad (35)$$

$$X_{kit} \leq I_{LS}x_{kit} \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in T \quad (36)$$

$$X_{kit} \geq (1 - \alpha_i)(1 - \rho\epsilon)I_{kt} - I_{LS}(1 - x_{kit}) \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in T \quad (37)$$

$$X_{kit} \leq (1 - \alpha_i)(1 - \rho\epsilon)(I_{kt} - I_{LI}(1 - x_{kit})) \quad \forall i \in N, \quad \forall k \in K, \quad \forall t \in T \quad (38)$$

Assumiu-se que o limite inferior para o número de indivíduos infectados I_{kt} é igual ao número de infectados ativos na semana t considerando que o nível de INF mais severo foi aplicado em todos os períodos anteriores ($I_{LI} = V_{kt}$), que pode ser calculado como um parâmetro conforme a Equação (39). O limite inferior foi definido como dependente do tempo com a finalidade de diminuir o tempo computacional, tornando-o mais restrito.

$$V_{k\ t+1} = V_{kt} + \beta(1 - \bar{\alpha})(1 - \rho\epsilon)V_{kt} - \rho\phi V_{kt} - (1 - \rho)\mu V_{kt} \\ \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (39)$$

Já o limite superior é o número máximo de indivíduos que podem ser infectados ($I_{LS} = I_{max}$), ou seja, a população total do país. Examinando sucessivamente os dois possíveis valores da variável binária x_{kit} , observa-se que as Equações (35) a (38) garantem que o valor de X_{kit} é igual a $(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt}$.

- **Linearização de $H_{kt}z_{1kt} = Y_{0kt}$**

Uma variável auxiliar Y_{0kt} foi definida para substituir o produto entre as variáveis $H_{kt}z_{1kt}$. Então, definiu-se que $H_{LI} \leq H_{kt} \leq H_{LS}$, em que H_{LI} é o limite inferior e H_{LS} é o limite superior para o número de médicos ativos H_{kt} . De modo a garantir que Y_{0kt} seja realmente igual a $H_{kt}z_{1kt}$, adicionaram-se as restrições (40) a (43) ao modelo.

$$Y_{0kt} \geq H_{LI}z_{1kt} \quad \forall k \in K, \quad \forall t \in T \quad (40)$$

$$Y_{0kt} \leq H_{LS}z_{1kt} \quad \forall k \in K, \quad \forall t \in T \quad (41)$$

$$Y_{0kt} \geq H_{kt} - H_{LS}(1 - z_{1kt}) \quad \forall k \in K, \quad \forall t \in T \quad (42)$$

$$Y_{0kt} \leq H_{kt} - H_{LI}(1 - z_{1kt}) \quad \forall k \in K, \quad \forall t \in T \quad (43)$$

Assumiu-se que o limite inferior para médicos ativos H_{kt} é igual a zero ($H_{LI} = 0$) e que o limite superior é o número de médicos ativos no período inicial ($H_{LS} = H_{k1}$). Avaliando os dois possíveis valores da variável binária z_{1kt} , observa-se que as Equações (40) a (43) garantem que o valor de Y_{0kt} é igual a $H_{kt}z_{1kt}$.

- **Linearização de $C_{kt}z_{rkt} = Y_{rkt}$**

Já para substituir o produto entre as variáveis $C_{kt}z_{rkt}$, uma variável auxiliar Y_{rkt} foi definida. Então, definiu-se que $C_{LI} \leq C_{kt} \leq C_{LS}$, em que C_{LI} e C_{LS} são, respectivamente, o limite inferior e o limite superior para o número de indivíduos que se encontram em estado crítico C_{kt} . De modo a garantir que a nova variável Y_{rkt} seja realmente igual a $C_{kt}z_{rkt}$, foram adicionadas as restrições (44) a (47) ao modelo.

$$Y_{rkt} \geq C_{LI}z_{rkt} \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in Rec \quad (44)$$

$$Y_{rkt} \leq C_{LS}z_{rkt} \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in Rec \quad (45)$$

$$Y_{rkt} \geq C_{kt} - C_{LS}(1 - z_{rkt}) \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in Rec \quad (46)$$

$$Y_{rkt} \leq C_{kt} - C_{LI}(1 - z_{rkt}) \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in Rec \quad (47)$$

Assumiu-se que o limite inferior para o número de indivíduos críticos C_{kt} é igual a zero ($C_{LI} = 0$) e que o limite superior é o número máximo de indivíduos infectados com sintomas graves ($C_{LS} = \rho I_{max}$). Examinando sucessivamente os dois possíveis valores da variável binária z_{rkt} , observa-se que as Equações (44) a (47) garantem que o valor de Y_{rkt} é igual a $C_{kt}z_{rkt}$.

- **Linearização de $s_{rkt}z_{0kt} = U_{rkt}$**

A fim de substituir o produto entre as variáveis $s_{rkt}z_{0kt}$, uma variável auxiliar U_{rkt} foi definida. Então, definiu-se que $s_{LI} \leq s_{rkt} \leq s_{LS}$, em que s_{LI} é o limite inferior e s_{LS} é o limite superior para a variável que representa a escassez de recursos de saúde, s_{rkt} , para médicos e leitos regulares. De modo a garantir que U_{rkt} realmente seja igual a $s_{rkt}z_{0kt}$, adicionaram-se as restrições (48) a (51) ao modelo.

$$U_{rkt} \geq s_{LI}z_{0kt} \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in \{1, 3\} \quad (48)$$

$$U_{rkt} \leq s_{LS}z_{0kt} \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in \{1, 3\} \quad (49)$$

$$U_{rkt} \geq s_{rkt} - s_{LS}(1 - z_{0kt}) \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in \{1, 3\} \quad (50)$$

$$U_{rkt} \leq s_{rkt} - s_{LI}(1 - z_{0kt}) \quad \forall k \in K, \quad \forall t \in T, \quad \forall r \in \{1, 3\} \quad (51)$$

Assumiu-se que o limite inferior para escassez de recursos s_{rkt} é igual a zero ($s_{LI} = 0$) e que a maior escassez possível ocorre quando o número de indivíduos infectados graves é máximo ($s_{LS} = \rho I_{max}$). Examinando os dois valores possíveis que a variável binária z_{0kt} pode assumir, observa-se que as Equações (48) a (51) garantem que o valor de U_{rkt} é igual a $s_{rkt}z_{0kt}$.

O modelo linearizado completo, com as substituições dos termos bilineares e as restrições adicionais apresentadas por meio das Equações (35) a (38) e (40) a (51), encontra-se no Apêndice B. Este modelo de PLIM, que incorpora a dinâmica epidêmica e questões sobre recursos de saúde, foi o modelo utilizado para o estudo de caso realizado neste trabalho e considerado como cenário base.

O modelo apresentado nesta dissertação propõe alguns aprimoramentos em relação ao modelo desenvolvido por Biswas e Alfandari (2022). Enquanto as Equações (2), (4) a (19), (25) a (31) e (35) a (51) permaneceram inalteradas, as Equações (1), (3), (20) a (24), (32) e (34) foram alteradas para atender os objetivos do presente trabalho. Conforme mencionado na seção 3.2, a função objetivo utilizada na Equação (1) é única e a Equação (3) foi adicionada ao modelo a partir de uma propriedade demonstrada por Biswas e Alfandari (2022). De modo geral, também buscou-se detalhar as equações tanto quanto possível para auxiliar na compreensão e os parâmetros λ_2 , λ_3 , γ_2 e γ_3 foram discriminados nas Equações (1), (20), (21b), (23) e (24). As Equações (22) a (24), que representam os indivíduos suscetíveis, recuperados e mortos, foram incorporadas ao modelo matemático. Ademais, fez-se correções em inconsistências verificadas no último termo da Equação (20), que representa os indivíduos críticos, e em um sinal de desigualdade da Equação (32).

O Capítulo 4 a seguir apresentado traz os principais resultados obtidos com o modelo proposto, além dos resultados alcançados para os cenários adicionais delineados e para as análises de sensibilidade conduzidas.

4 RESULTADOS E DISCUSSÕES

O modelo de PLIM apresentado no Capítulo 3 é empregado em um estudo de caso envolvendo a pandemia de COVID-19 nas 27 UF do Brasil. Na seção 4.1 são descritos os dados e parâmetros utilizados no estudo de caso, na seção 4.2 são apresentados os resultados da implementação computacional para os diferentes cenários e na seção 4.3 é realizada uma análise de sensibilidade de parâmetros do modelo.

4.1 Configuração dos parâmetros

Os dados e parâmetros utilizados na implementação do modelo matemático foram coletados para a realidade brasileira a partir de órgãos governamentais e da literatura sobre a COVID-19. Os parâmetros incluem informações epidêmicas, de recursos, populacionais e econômicas que se encontram resumidas nos Quadros 7 a 10. Ademais, é fornecida uma explicação mais detalhada para os parâmetros que demandaram cálculos para a sua obtenção, as hipóteses adotadas e as fontes de dados utilizadas.

O Quadro 7 apresenta um resumo dos parâmetros epidêmicos que foram utilizados no modelo.

Quadro 7 – Resumo dos parâmetros epidêmicos do modelo

(continua)

Parâmetro	Descrição	Valor	Referência
β	Taxa de transmissão semanal por pessoa	1,45	Calculado a partir de Canabarro <i>et al.</i> (2020) e da Equação (52) de Gomes, Monteiro e Rocha (2020)
μ	Taxa semanal na qual uma infecção não grave se recupera	0,409	Calculado a partir de OPAS (2020, p. 5)
φ	Taxa semanal em que uma pessoa infectada entra no estado crítico	0,933	Calculado a partir de Di Domenico <i>et al.</i> (2020)
γ_2	Taxa semanal em que uma infecção crítica deixa a UTI	0,33	Calculado a partir de OPAS (2020, p. 6)
γ_3	Taxa semanal em que uma infecção crítica deixa o leito regular	0,70	Calculado a partir de Salje <i>et al.</i> (2020)
ρ	Proporção de infectados que se tornam críticos (precisam de hospitalização)	0,20	Noronha <i>et al.</i> (2020), OPAS (2020, p. 7)

Quadro 7 – Resumo dos parâmetros epidêmicos do modelo

(conclusão)

Parâmetro	Descrição	Valor	Referência
θ	Proporção de indivíduos críticos que necessitam de leitos de UTI	0,25	Noronha <i>et al.</i> (2020)
λ_2	Proporção de indivíduos hospitalizados em UTI que se recuperam	0,74	Calculado a partir de Di Domenico <i>et al.</i> (2020)
λ_3	Proporção de indivíduos hospitalizados em leitos regulares que se recuperam	0,945	Calculado a partir de Salje <i>et al.</i> (2020)
ϵ	Proporção de pacientes críticos que se autoisolam	0,50	OPAS (2020, p. 7)
α_i	Redução na taxa de transmissão por nível de INF i , $\forall i \in N$	{0; 0,18148; 0,24901; 0,39262; 0,60161}	Calculado a partir de Prem, Cook e Jit (2017) e Biswas e Alfandari (2022)
w_i	Peso atribuído a cada nível de INF i , $\forall i \in N$	{1; 2; 3; 4; 5}	Autoria própria (2023)

Fonte: Autoria própria (2023).

Como no modelo os períodos são definidos em semanas, todos os parâmetros de transição usados para descrever as taxas de movimento entre os compartimentos foram convertidos em parâmetros semanais.

O parâmetro β descreve a eficácia do processo infeccioso e pode ser medido indiretamente. Segundo Gomes, Monteiro e Rocha (2020, p. 5), o valor de β pode ser calculado conforme a Equação (52).

$$R_0 = \beta T_{inf} \quad (52)$$

Onde R_0 é o índice de reprodução basal e T_{inf} é o tempo de infecção, período no qual o infectado está infeccioso, isto é, pode transmitir a doença. Desse modo, utilizando o valor do índice de reprodução basal R_0 estimado em 2,9 por Canabarro *et al.* (2020, p. 8) para o Brasil em 21 de março de 2020 e o tempo de infecção T_{inf} de 14 dias (ou 2 semanas) indicado em OPAS (2020, p. 5), foi possível obter a taxa de transmissão β .

Já os parâmetros μ , φ , γ_2 e γ_3 são equivalentes, respectivamente, ao inverso do tempo de recuperação (OPAS, 2020, p. 5), do tempo até a hospitalização (DI DOMENICO *et al.*, 2020), do tempo de permanência na UTI (OPAS, 2020, p. 6) e do tempo de permanência em leitos regulares (SALJE *et al.*, 2020).

As proporções de indivíduos hospitalizados que se recuperam λ_2 e λ_3 foram obtidas por meio da ponderação destes parâmetros disponibilizados por faixa etária em Di Domenico *et al.* (2020) e Salje *et al.* (2020), pela população brasileira nas respectivas faixas etárias (IBGE, 2020).

Adicionalmente, utilizando os pressupostos e fórmulas disponibilizadas por Biswas e Alfandari (2022, p. 1388) e as matrizes de contato social para o Brasil fornecidas em Prem, Cook e Jit (2017), foi possível estimar a redução na taxa de transmissão α_i para o país considerando cada nível i de INF adotado.

O Quadro 8 resume os parâmetros que se referem ao número de indivíduos nos compartimentos. Os valores dos parâmetros diferenciados para cada UF k são disponibilizados no Apêndice C.

Quadro 8 – Resumo dos parâmetros relativos ao número de indivíduos

Parâmetro	Descrição	Valor	Referência
S_{k1}	Número inicial de indivíduos suscetíveis na UF k , $\forall k \in K$	Apêndice C	Calculado a partir de CONASS (2020)
I_{k1}	Número inicial de indivíduos infectados na UF k , $\forall k \in K$	Apêndice C	Calculado a partir de CONASS (2020) e PRADO <i>et al.</i> (2020)
C_{k1}	Número inicial de indivíduos críticos na UF k , $\forall k \in K$	Apêndice C	Calculado a partir de CONASS (2020)
R_{k1}	Número inicial de indivíduos recuperados na UF k , $\forall k \in K$	Apêndice C	Canabarro <i>et al.</i> (2020)
M_{k1}	Número inicial de indivíduos mortos na UF k , $\forall k \in K$	Apêndice C	CONASS (2020)
V_{kt}	Limite inferior teórico de infecções para o período t e UF k , $\forall t \in T$, $\forall k \in K$	Apêndice C	Calculado a partir de Biswas e Alfandari (2022)
I_{max}	Limite superior teórico de indivíduos infectados para todos os períodos	212.077.375	IBGE (2020)

Fonte: Autoria própria (2023).

Os números iniciais de indivíduos infectados e mortos por UF foram obtidos utilizando os dados oficiais relatados no Painel Conass Covid-19 (CONASS, 2020) para 29 de março de 2020 (início da semana epidemiológica 14). Entretanto, como o Brasil realizava poucos testes naquele momento e, conseqüentemente, havia uma alta subnotificação de casos, considerou-se que o número de infectados inicialmente era 11 vezes maior, conforme conclusões apresentadas por Prado *et al.* (2020)⁴. Para o

⁴ De acordo com a OPAS (2020, p. 5), um maior número de infecções iniciais também pode ser considerado em modelagens para se levar em conta os casos assintomáticos desconhecidos.

número inicial de indivíduos críticos, considerou-se que uma proporção ρ dos indivíduos infectados relatados oficialmente se encontravam em estado crítico.

Como inicialmente o número de recuperados era insignificante, definiu-se $R_{k1} = 0, \forall k \in K$, o que segundo Canabarro *et al.* (2020), é uma suposição comum para modelar infecções em estágios iniciais, seja no caso do Brasil ou de outros países. Já o número inicial de indivíduos suscetíveis é dado pela população, descontando-se o número correspondente de infectados, críticos, recuperados e mortos.

O Quadro 9 apresenta um resumo dos parâmetros relacionados aos recursos médicos considerados no modelo.

Quadro 9 – Resumo dos parâmetros relacionados aos recursos médicos

Parâmetro	Descrição	Valor	Referência
l_{2k}	Número de leitos de UTI ($r = 2$) na UF k , $\forall k \in K$	Apêndice C	BRASIL (2020c)
l_{3k}	Número de leitos regulares ($r = 3$) na UF k , $\forall k \in K$	Apêndice C	BRASIL (2020b)
η_{rk}	Proporção do recurso r alocado para casos não-COVID na UF k , $\forall r \in Rec, \forall k \in K$	Apêndice C	Calculado a partir de BRASIL (2020b, 2020c)
H_{k1}	Número inicial de médicos ativos na UF k , $\forall k \in K$	Apêndice C	Calculado a partir de Scheffer <i>et al.</i> (2020)
m	Número de leitos atendidos por um médico por turno	10	CFM (2020)
$\bar{\tau}$	Tempo médio, em semanas, de quarentena para médicos após serem infectados	2	Biswas e Alfandari (2022)

Fonte: Autoria própria (2023).

Os dados de oferta de leitos regulares e de UTI por UF foram obtidos junto ao Cadastro Nacional dos Estabelecimentos de Saúde do Brasil (CNES), do Ministério da Saúde, referente ao mês de junho de 2020 (BRASIL, 2020b, 2020c). Para leitos de UTI, o número de leitos e a proporção alocada para o tratamento de pacientes com COVID-19 foram obtidos diretamente dos dados do CNES, pois os mesmos são informados de forma detalhada. Já para obter o número total de leitos regulares disponíveis para pacientes de COVID-19, foram excluídos os leitos obstétricos, pediátricos, hospital/dia e especiais, de forma semelhante ao realizado por Noronha *et al.* (2020). Dos leitos regulares restantes, considerou-se que a proporção alocada para pacientes de COVID-19 é semelhante à adotada para leitos de UTI, devido à ausência de dados detalhados.

Com relação ao número de médicos para cada UF, o dado foi retirado de um estudo de demografia médica conduzido por Scheffer *et al.* (2020). Para obter a proporção de médicos aptos a atender casos de COVID-19, foram desconsiderados os médicos acima de 60 anos, que fazem parte do grupo de risco, e foi considerado que todos os médicos generalistas e 40% dos médicos especialistas realizam esses atendimentos. Além disso, considerou-se que um médico atende em média 10 pacientes (CFM, 2020).

Por fim, o Quadro 10 apresenta um resumo dos parâmetros de mortalidade prematura, populacionais e econômicos utilizados no modelo.

Quadro 10 – Resumo dos parâmetros populacionais, econômicos e de mortalidade

Parâmetro	Descrição	Valor	Referência
P	População total do país	212.077.375	IBGE (2020)
p_k	População da UF k , $\forall k \in K$	Apêndice C	IBGE (2020)
PIB_{0k}	Produto Interno Bruto inicial para a UF k , $\forall k \in K$	Apêndice C	IBGE (2021b)
ΔPIB_{ki}	Variação no Produto Interno Bruto por UF k e por nível de INF i , $\forall k \in K$, $\forall i \in N$	Apêndice C	Calculado a partir de Porsse <i>et al.</i> (2020)
b c	Parâmetros de modelo de Norris (2006) para estimar a expectativa de vida a partir do PIB <i>per capita</i>	1499,867350 0,499293	Calculado a partir de IBGE (2018, 2021b) e da Equação (53) de Norris (2006)
$AVP_{médio k}$	Anos de Vida Perdidos médio por UF k , $\forall k \in K$	Apêndice C	Calculado a partir de BRASIL (2020d)

Fonte: Autoria própria (2023).

Conforme pode ser visto no Quadro 10, os dados populacionais para o ano de 2020 foram retirados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2020), assim como os valores do PIB inicial por UF (PIB_{0k}) para o ano de 2019 (IBGE, 2021b).

Já os valores de ΔPIB_{ki} foram obtidos a partir do estudo de Porsse *et al.* (2020), o qual projeta os impactos econômicos do surto de COVID-19 no Brasil com detalhamento regional e setorial, por meio da utilização de um modelo de equilíbrio geral computável (EGC) dinâmico e inter-regional, denominado TERM-UF e que é totalmente desagregado por 27 UF brasileiras e 29 setores econômicos. O modelo considera um choque negativo de oferta de trabalho devido às taxas de morbidade (número de indivíduos infectados pelo vírus e temporariamente incapacitados para o trabalho) e mortalidade (número de indivíduos que morrem) causadas pela doença,


além de um fechamento temporário ou redução de atividades econômicas não essenciais, principalmente serviços, devido ao isolamento social. Os autores também realizaram uma análise de sensibilidade quanto ao tempo de paralisação da atividade econômica não essencial, devido à incerteza de sua duração. Assim, foram realizadas simulações para três e seis meses de paralisação (PORSSE *et al.*, 2020). Os valores referentes ao fechamento de três meses obtidos pelo estudo foram adotados para a variação no PIB atrelada à INF nível 5, porém desconsiderando a projeção de crescimento do Banco Central utilizada pelos autores. Para os demais níveis de INF, os valores foram obtidos usando as proporções de custo econômico adotadas por Biswas e Alfandari (2022) em seu modelo.

Os parâmetros b e c foram obtidos por meio de uma relação não linear estimada entre a expectativa de vida ao nascer e o PIB *per capita* utilizando dados de 2019 (IBGE, 2018, 2021b) para as 27 UF brasileiras. De maneira semelhante a Norris (2006, p. 99), o modelo estimado tem a forma da Equação (53).

$$EV = a - b * PIBPC^{-c} \quad (53)$$

Onde EV é a expectativa de vida em anos, $PIBPC$ é o PIB *per capita* em reais, ambos para o ano de 2019, e a , b e c são parâmetros estimados para o modelo. O Gráfico 1 representa essa relação para as UF do Brasil e também apresenta os parâmetros estimados e a porcentagem de variância explicada pelo modelo (R^2). Vale notar que o ponto nominado no Gráfico 1 como “Brasil” traz os valores médios de expectativa de vida em relação ao PIB *per capita*; os estados com maiores valores de PIB *per capita* estão, portanto, à direita do referido ponto médio.

Gráfico 1 – Expectativa de vida ao nascer em relação ao PIB *per capita*



Fonte: Autoria própria (2023).

Por fim, com a intenção de obter o indicador Anos de Vida Perdidos (AVP) médio para indivíduos que morrem por causa da COVID-19 no Brasil por UF, foram coletados dados de óbitos de todo o ano de 2020, por faixa etária e por UF, para a Classificação Internacional de Doenças (CID) B34.2, que é o código para infecção por coronavírus de localização não especificada (BRASIL, 2020d). Segundo o IBGE (2021a), se o Brasil não tivesse vivenciado uma crise de mortalidade, a expectativa de vida seria de 76,8 anos para o total da população em 2020. Este valor foi utilizado para calcular os AVP por faixa etária, subtraindo da expectativa de vida o ponto médio de cada faixa etária considerada. Ressalta-se que para a faixa etária acima de 80 anos, para evitar um valor de AVP negativo, considerou-se que esses indivíduos teriam mais 5 anos de vida. Esses AVP foram multiplicados pelo número de óbitos por faixa etária e somados, resultando nos AVP totais para cada UF. Para obter o AVP médio por UF ($AVP_{médio\ k}$), dividiu-se os AVP totais pelo número total de óbitos. Os valores encontrados aproximam-se dos encontrados por Quast *et al.* (2022) e Mascarello *et al.* (2022).

4.2 Resultados da implementação

Com os parâmetros adaptados para a realidade brasileira coletados, o modelo de PLIM foi implementado no ambiente de modelagem e otimização IBM ILOG CPLEX *Optimization Studio*, versão 22.1.1.0, licença educacional e todos os experimentos computacionais foram realizados em um *laptop* equipado com processador AMD Ryzen 7 2700U com Radeon Vega Mobile Gfx de 2,20 GHz, 12 GB de RAM e com sistema operacional Windows 10, 64 bits.

Dado o ambiente de mudança contínua da pandemia, o modelo resultante foi resolvido para um horizonte de planejamento de 13 semanas (3 meses) para todos os cenários considerados. Os resultados são apresentados de maneira detalhada para o cenário base, enquanto que para os cenários adicionais (cenários 1 e 2), os resultados são apresentados de forma mais sucinta, comparando-os ao cenário base. Vale ressaltar que os resultados são obtidos por um método de otimização orientado por uma função de avaliação, Equação (1), o qual busca minimizar o somatório dos AVP em todo o horizonte de análise considerado.

4.2.1 Resultados para o cenário base

O modelo para o cenário base é composto pelas Equações (1) e (54) a (98), as quais se encontram listadas no Apêndice B. A formulação matemática gerada apresentou 11.988 variáveis, das quais 3.159 são binárias e 8.829 são variáveis contínuas, além de 23.193 restrições. O tempo computacional até a obtenção da solução ótima foi de aproximadamente 80 segundos.

Para o cenário base, o valor minimizado obtido para a função objetivo foi de 4.056.237,87 Anos de Vida Perdidos por causa da COVID-19 para todo o Brasil. A parcela epidêmica contribuiu com aproximadamente 16% deste valor e a parcela econômica com 84%. A Tabela 1 informa por UF o número de AVP para as parcelas epidêmica e econômica e os valores totais, classificados em ordem alfabética por UF.

Tabela 1 – Anos de Vida Perdidos por UF para o cenário base

UF	Parcela epidêmica		Parcela econômica		Total	
	AVP	(%)	AVP	(%)	AVP	(%)
AC	957	0,15	41.532	1,22	42.489	1,05
AL	7.253	1,11	41.976	1,23	49.229	1,21

(continua)

Tabela 1 – Anos de Vida Perdidos por UF para o cenário base

(continuação)

UF	Parcela epidêmica		Parcela econômica		Total	
	AVP	(%)	AVP	(%)	AVP	(%)
AP	2.104	0,32	13.444	0,39	15.547	0,38
AM	5.639	0,86	115.094	3,38	120.732	2,98
BA	39.357	6,04	327.277	9,61	366.634	9,04
CE	11.012	1,69	368.924	10,84	379.936	9,37
DF	6.583	1,01	17.117	0,50	23.700	0,58
ES	11.033	1,69	50.057	1,47	61.090	1,51
GO	41.944	6,43	98.058	2,88	140.002	3,45
MA	11.645	1,79	82.223	2,42	93.868	2,31
MT	11.831	1,81	22.995	0,68	34.826	0,86
MS	8.326	1,28	33.196	0,98	41.522	1,02
MG	105.366	16,16	296.359	8,71	401.725	9,90
PA	10.158	1,56	74.447	2,19	84.605	2,09
PB	19.791	3,04	38.349	1,13	58.140	1,43
PR	50.358	7,72	163.860	4,81	214.218	5,28
PE	21.864	3,35	167.206	4,91	189.070	4,66
PI	6.469	0,99	46.098	1,35	52.567	1,30
RJ	34.667	5,32	161.227	4,74	195.894	4,83
RN	7.432	1,14	75.427	2,22	82.860	2,04
RS	56.578	8,68	188.154	5,53	244.733	6,03
RO	7.104	1,09	21.643	0,64	28.747	0,71
RR	1.308	0,20	7.008	0,21	8.315	0,21
SC	30.662	4,70	139.333	4,09	169.995	4,19
SP	127.263	19,52	770.179	22,62	897.442	22,12
SE	8.023	1,23	25.510	0,75	33.533	0,83
TO	7.321	1,12	17.497	0,51	24.818	0,61
Brasil	652.051	100	3.404.187	100	4.056.238	100

Fonte: Autoria própria (2023).


Os AVP de São Paulo (SP) representaram aproximadamente um quinto do total nacional. As cinco principais UF restantes em termos de AVP totais foram: Minas Gerais (MG), Ceará (CE), Bahia (BA), Rio Grande do Sul (RS) e Paraná (PR), que juntas representam 61,7% do total.

Ao analisar as parcelas epidêmica e econômica separadamente, percebe-se que as UF que apresentaram as maiores contribuições para a parcela epidêmica foram: São Paulo (SP), Minas Gerais (MG), Rio Grande do Sul (RS), Paraná (PR), Goiás (GO) e Bahia (BA). Estas seis UF representam 64,5% do total de AVP para a parcela epidêmica. Destas UF, apenas São Paulo (SP), Minas Gerais (MG) e Rio Grande do Sul (RS) estavam entre as UF que tinham o maior número de infectados no início do horizonte de planejamento.

Já as UF que apresentaram maiores contribuições para a parcela econômica foram: São Paulo (SP), Ceará (CE), Bahia (BA), Minas Gerais (MG), Rio Grande do Sul (RS) e Pernambuco (PE). Estas seis UF contribuem com 62,2% do total de AVP para a parcela econômica. Observa-se que São Paulo (SP), Minas Gerais (MG), Rio

Grande do Sul (RS) e Bahia (BA) aparecem entre as UF mais representativas em ambas as parcelas, epidêmica e econômica.

Complementarmente à Tabela 1, o Gráfico 2 ilustra os AVP para as parcelas epidêmica e econômica por UF. As UF estão classificadas em ordem decrescente pelo número de AVP totais.



Fonte: Autoria própria (2023).

De maneira análoga a outros estudos (BONATTO, 2013; OH *et al.*, 2020; QUAST *et al.*, 2021), buscou-se avaliar também os AVP por habitantes. Assim, a

Tabela 2 mostra os AVP calculados por 100.000 habitantes por UF para as parcelas epidêmica e econômica e para o total, classificados em ordem alfabética por UF.

Tabela 2 – Anos de Vida Perdidos por 100.000 habitantes por UF

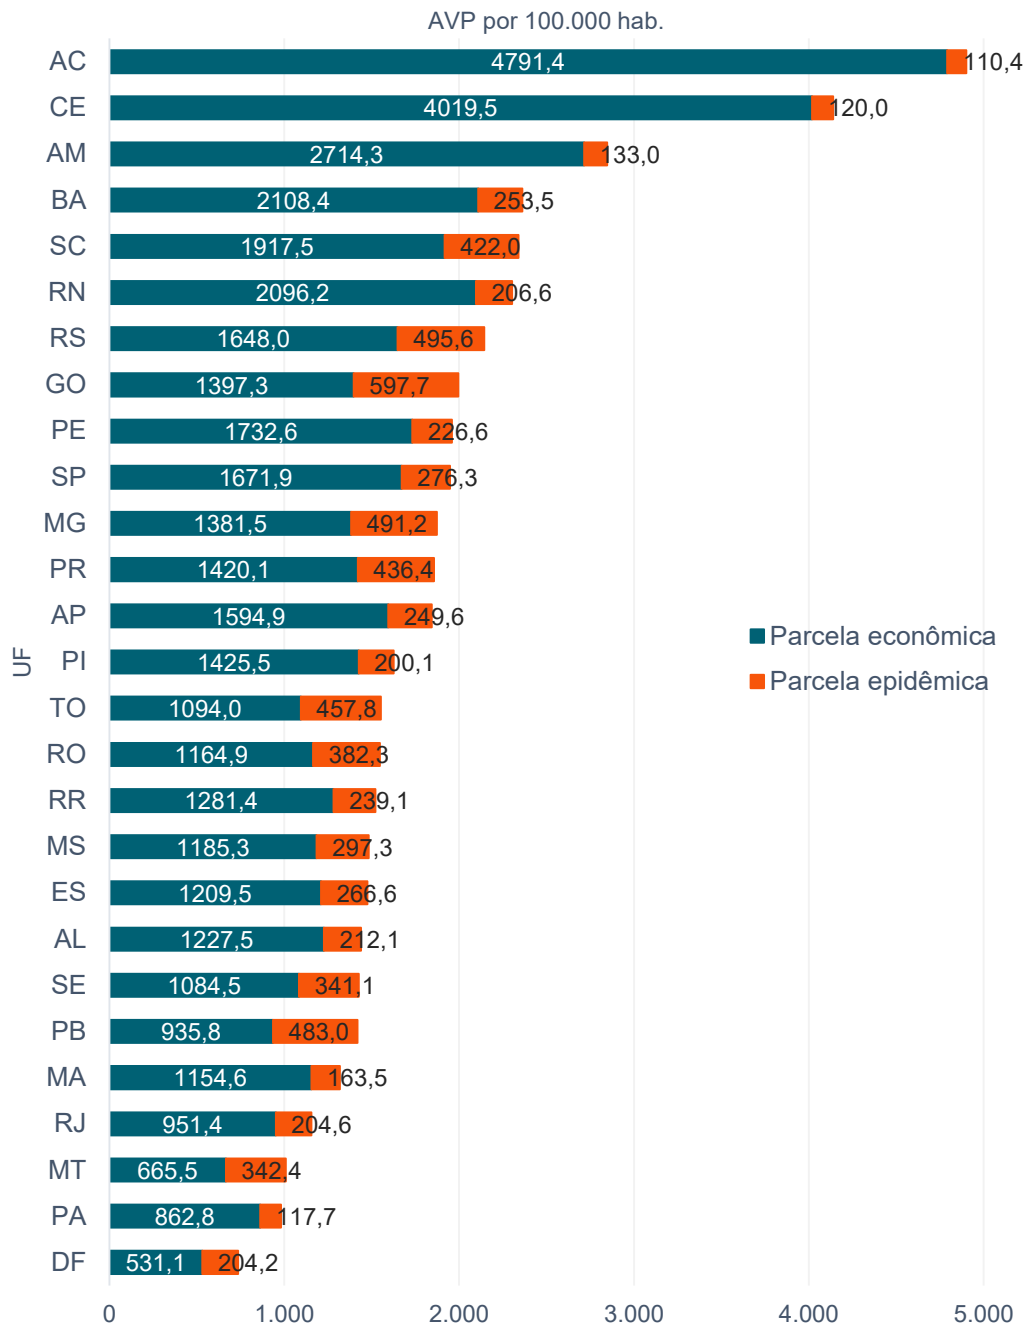
UF	Parcela epidêmica		Parcela econômica		Total
	AVP por 100.000 hab.	(%)	AVP por 100.000 hab.	(%)	AVP por 100.000 hab.
AC	110,4	2,3	4.791,4	97,7	4.901,8
AL	212,1	14,7	1.227,5	85,3	1.439,6
AP	249,6	13,5	1.594,9	86,5	1.844,5
AM	133,0	4,7	2.714,3	95,3	2.847,3
BA	253,5	10,7	2.108,4	89,3	2.361,9
CE	120,0	2,9	4.019,5	97,1	4.139,5
DF	204,2	27,8	531,1	72,2	735,3
ES	266,6	18,1	1.209,5	81,9	1.476,1
GO	597,7	30,0	1.397,3	70,0	1.995,0
MA	163,5	12,4	1.154,6	87,6	1.318,2
MT	342,4	34,0	665,5	66,0	1.008,0
MS	297,3	20,1	1.185,3	79,9	1.482,5
MG	491,2	26,2	1.381,5	73,8	1.872,7
PA	117,7	12,0	862,8	88,0	980,5
PB	483,0	34,0	935,8	66,0	1.418,8
PR	436,4	23,5	1.420,1	76,5	1.856,5
PE	226,6	11,6	1.732,6	88,4	1.959,1
PI	200,1	12,3	1.425,5	87,7	1.625,5
RJ	204,6	17,7	951,4	82,3	1.156,0
RN	206,6	9,0	2.096,2	91,0	2.302,8
RS	495,6	23,1	1.648,0	76,9	2.143,6
RO	382,3	24,7	1.164,9	75,3	1.547,2
RR	239,1	15,7	1.281,4	84,3	1.520,5
SC	422,0	18,0	1.917,5	82,0	2.339,5
SP	276,3	14,2	1.671,9	85,8	1.948,2
SE	341,1	23,9	1.084,5	76,1	1.425,6
TO	457,8	29,5	1.094,0	70,5	1.551,8
Brasil	307,5	16,1	1.605,2	83,9	1.912,6

Fonte: Autoria própria (2023).

Ao analisar o indicador considerando a população das UF, pode-se perceber que as UF que apresentam as maiores contribuições diferem das apresentadas na Tabela 1 e no Gráfico 2. Neste ponto, as UF que apresentaram os maiores totais de AVP por 100.000 habitantes foram: Acre (AC), Ceará (CE), Amazonas (AM), Bahia (BA), Santa Catarina (SC) e Rio Grande do Norte (RN). Vale ressaltar que, destas UF, apenas o Acre (AC) figura entre os estados com as menores populações do país.

De modo a apoiar a análise, o Gráfico 3 exibe os AVP por 100.000 habitantes por UF para as parcelas epidêmica e econômica, classificando as UF em ordem decrescente pelo total de AVP por 100.000 habitantes.

Gráfico 3 – Anos de Vida Perdidos por 100.000 habitantes por UF



Fonte: Autoria própria (2023).

Conforme mostrado na Tabela 2 e no Gráfico 3, as UF que apresentaram os maiores valores de AVP por 100.000 habitantes para a parcela econômica foram as mesmas que apresentaram os maiores valores totais: Acre (AC), Ceará (CE), Amazonas (AM), Bahia (BA), Rio Grande do Norte (RN) e Santa Catarina (SC).

Já para a parcela epidêmica, Goiás (GO), Rio Grande do Sul (RS), Minas Gerais (MG), Paraíba (PB), Tocantins (TO) e Paraná (PR) foram as UF que apresentaram os valores mais elevados. Com exceção de Paraíba (PB) e Tocantins

(TO), os demais estados já estavam listados entre as maiores contribuições para a parcela epidêmica considerando os AVP brutos na Tabela 1.

Com relação às decisões referentes às INF que são indicadas pelo modelo matemático, apresenta-se a Figura 5, a qual ilustra o resultado das decisões para as 27 UF brasileiras e para cada semana do horizonte de planejamento.

Figura 5 – Decisões de INF por UF para o cenário base

UF	Tempo (em semanas)												
	1	2	3	4	5	6	7	8	9	10	11	12	13
AC	5	5	5	5	5	5	5	5	3	2	1	1	1
AL	4	4	4	4	3	3	2	2	2	2	1	1	1
AP	4	4	4	4	4	3	3	3	3	2	1	1	1
AM	5	5	5	5	5	5	5	4	3	2	1	1	1
BA	5	5	4	4	3	3	3	3	2	2	1	1	1
CE	5	5	5	5	5	5	5	4	4	2	1	1	1
DF	5	5	5	5	5	5	5	5	5	2	1	1	1
ES	5	4	4	4	4	4	3	3	3	2	1	1	1
GO	4	4	4	3	3	3	3	3	3	2	1	1	1
MA	3	3	3	3	3	3	3	2	2	2	1	1	1
MT	3	3	3	3	3	3	3	3	3	2	1	1	1
MS	5	5	4	4	4	3	3	3	3	2	1	1	1
MG	4	4	4	4	3	3	3	3	3	2	1	1	1
PA	3	3	3	3	3	3	3	3	2	2	1	1	1
PB	3	3	3	3	2	2	2	2	2	2	1	1	1
PR	4	4	4	4	4	4	4	3	3	2	1	1	1
PE	4	4	4	4	4	3	3	3	2	2	1	1	1
PI	4	3	3	3	3	3	3	2	2	2	1	1	1
RJ	5	5	5	5	5	4	4	3	3	3	2	1	1
RN	5	5	5	4	3	3	3	3	3	3	1	1	1
RS	5	4	4	4	4	4	4	3	3	2	1	1	1
RO	3	3	3	3	3	3	2	2	2	2	1	1	1
RR	5	5	5	5	5	4	4	3	3	3	2	1	1
SC	5	5	5	4	4	4	4	3	3	2	1	1	1
SP	5	5	5	5	5	4	3	3	3	3	1	1	1
SE	4	4	4	4	4	3	3	3	3	2	1	1	1
TO	4	4	4	3	3	3	3	3	3	2	1	1	1

Fonte: Autoria própria (2023).

Na Figura 5, pode-se perceber que o nível de INF indicado variou consideravelmente entre as UF, principalmente nas primeiras semanas. Enquanto o nível de INF mais elevado (nível 5) foi indicado para 13 UF, as demais variaram entre os níveis 3 ou 4 inicialmente.

Estas decisões heterogêneas entre as UF podem ser explicadas a partir de algumas hipóteses. Dentre estas, a consideração de diferentes valores de queda no PIB por UF (ΔPIB_{ki}), conforme determinado por Porsse *et al.* (2020), que leva em conta a participação dos diferentes setores econômicos na composição da economia

de cada UF, bem como uma queda de atividade em setores específicos em caso de um fechamento temporário de três meses. Também, a população e o PIB inicial de cada UF, os quais podem influenciar na parcela econômica da função objetivo e, conseqüentemente, nas decisões relacionadas às INF. Outro fator relevante é o número inicial de infectados (I_{k1}) diferente para cada UF, já que na data considerada como início do horizonte de planejamento, a epidemia estava mais avançada em algumas UF do que em outras, como é o caso de São Paulo (SP) e Rio de Janeiro (RJ). Pode-se citar, ainda, a quantidade de recursos médicos disponíveis em cada UF.

Ressalta-se que estes fatores interagem e podem influenciar de maneira conjunta nas decisões do modelo matemático. O Distrito Federal (DF), por exemplo, foi a UF que teve a INF nível 5 indicada pelo modelo para o maior período de tempo, 10 semanas. Isto porque a queda no PIB estimada por Porsse *et al.* (2020) para a UF em caso de um fechamento é menor do que para outras UF, além de seu PIB *per capita* ser disparadamente o maior do país, conforme mostra o Gráfico 1, o que tem influência na parcela econômica da função objetivo e, por conseguinte, nas decisões relacionadas às INF. Além disso, o DF apresentava o quarto maior número inicial de infectados.


Já mais ao final do horizonte de planejamento considerado, as decisões tornam-se mais homogêneas e a partir da semana 11, o modelo sugere uma redução na severidade das INF indicando o nível 1 para quase todas as UF, o que ocorre de fato na semana 12.

A seguir, com auxílio de gráficos, são apresentados os resultados da evolução da doença para as variáveis de estado epidêmico de infectados, mortos e críticos, consideradas no modelo compartimental. Ressalta-se que, por mais que estas variáveis tenham sido implementadas no domínio dos números reais devido às questões computacionais, os resultados foram arredondados e são apresentados como números inteiros.

O número acumulado de indivíduos infectados por semana para o Brasil pode ser visto no Gráfico 4. Ao longo das 13 semanas consideradas, o número total de infectados foi de 2.463.528 pessoas. Verifica-se que a partir da semana 10, começa a haver um crescimento acentuado das infecções, o que pode ser explicado pela flexibilização das medidas restritivas que aconteceu na maioria das UF a partir desta semana, conforme mostra a Figura 5. Nas duas últimas semanas do horizonte de

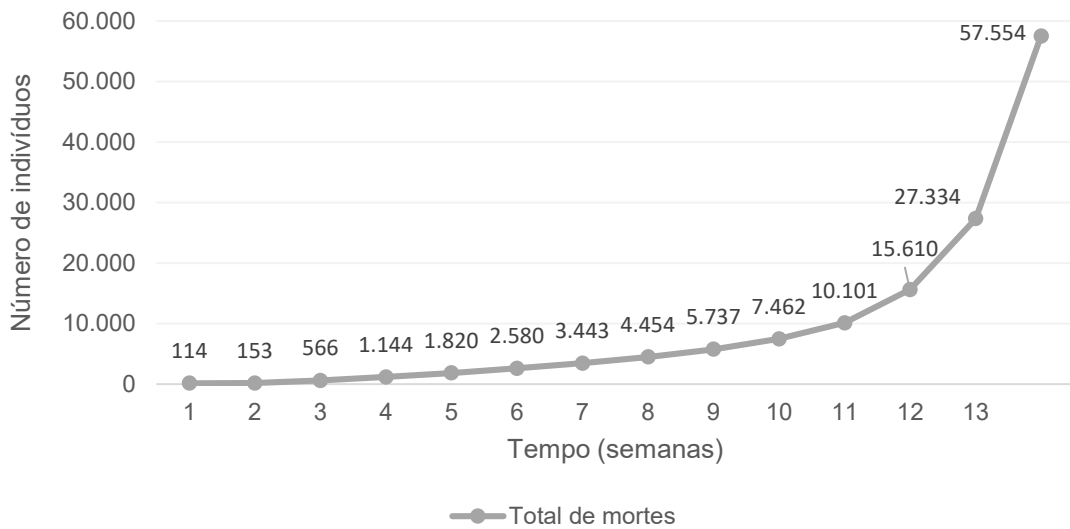
planejamento, as taxas de crescimento das infecções atingiram 58% e 66%, respectivamente.

Gráfico 4 – Número acumulado de infectados por semana no Brasil



Fonte: Autoria própria (2023).

Já o Gráfico 5 apresenta o número acumulado de mortos por semana no Brasil. Conforme resultados do modelo, um total de 57.554 mortes são registradas ao final da semana 13. Nas duas últimas semanas do horizonte de planejamento, as taxas de crescimento das mortes foram de 75% e 111%, respectivamente.

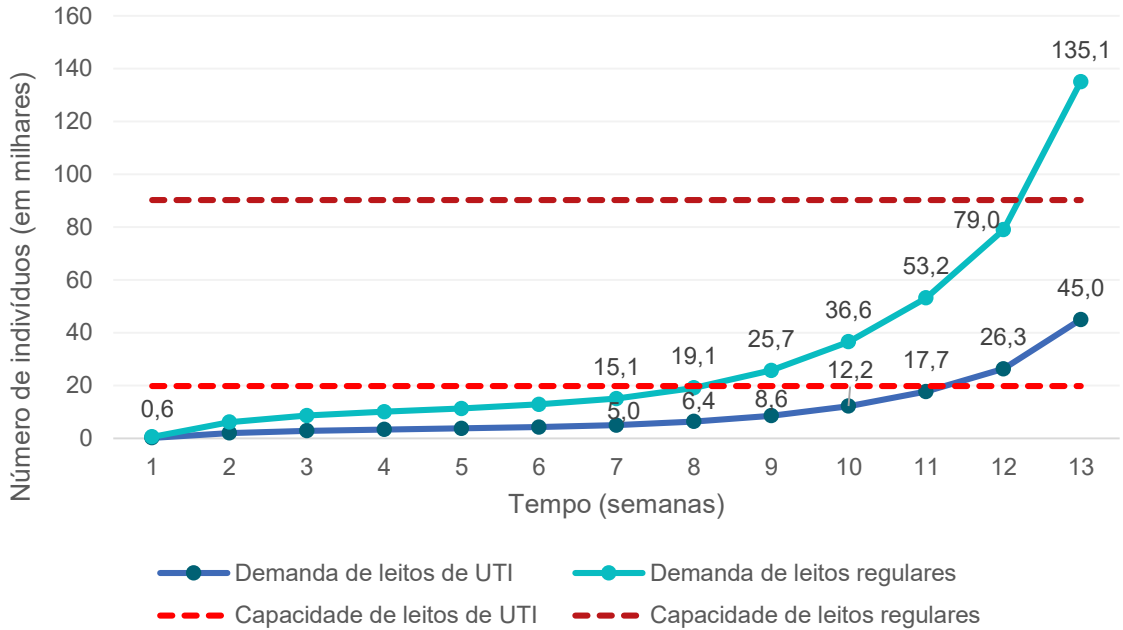
Gráfico 5 – Número acumulado de mortos por semana no Brasil

Fonte: Autoria própria (2023).

Do total de mortes, cerca de 60% (34.790 mortes) são atribuídas à escassez de leitos de UTI, situação que começa a ocorrer em Goiás (GO), Rio Grande do Sul (RS) e Tocantins (TO) na semana 10 e se propaga para todas as UF nas semanas posteriores. Este número elevado se deve à hipótese adotada no modelo, a qual estabeleceu que a escassez de leitos de UTI leva o indivíduo à morte, conforme mencionado no Capítulo 3. Além disso, destaca-se que não foi considerada a possibilidade de abertura de novos leitos no modelo, ou seja, a capacidade de leitos é constante ao longo das 13 semanas, conforme mostrado no Gráfico 6.

O Gráfico 6 ilustra o número de indivíduos em estado crítico no Brasil e que demandam algum tipo de leito hospitalar, sejam leitos regulares ou de UTI. Quanto ao número de leitos de UTI, é possível perceber que a partir da semana 12 a demanda por leitos ultrapassa a capacidade nacional. Com relação ao número de leitos regulares, a demanda extrapola a capacidade na semana 13, atrasando a recuperação dos pacientes que não conseguem este tipo de leito.


Gráfico 6 – Número de indivíduos críticos por semana no Brasil



Fonte: Autoria própria (2023).


A situação detalhada da escassez de leitos regulares e de leitos de UTI por UF pode ser vista, respectivamente, nos Gráfico 7 e Gráfico 8. Observa-se no Gráfico 7 que Minas Gerais (MG) e São Paulo (SP) registraram a maior escassez de leitos regulares, a qual ocorre sobretudo nas semanas 12 e 13.

Gráfico 7 – Escassez de leitos regulares por UF



Fonte: Autoria própria (2023).

Já no Gráfico 8, observando a escassez de leitos de UTI por UF ao longo do horizonte de planejamento, percebe-se que a partir da semana 11 a falta de leitos começa a ser significativa em algumas UF e a situação se agrava nas duas semanas posteriores.



Fonte: Autoria própria (2023).

No caso de leitos de UTI, Minas Gerais (MG) e São Paulo (SP) também foram as UF que registraram maior escassez, seguidas por Rio Grande do Sul (RS), Paraná (PR), Goiás (GO) e Bahia (BA). Justamente estas foram as UF que apresentaram as maiores contribuições para os AVP da parcela epidêmica da função objetivo.

Ressalta-se que o modelo matemático considera a obtenção da resposta de menor valor de função objetivo para um dado horizonte de análise. Ou seja, considerando-se as 13 semanas envolvidas, o modelo determina as decisões que conduzem ao menor valor de somatório para a função de avaliação nestas semanas que compõe o horizonte de análise. Contudo, ao findar o referido horizonte, é possível que as condições de término do cenário demandem ações severas em um possível novo ciclo de análise, com início a partir do término da semana 13. Portanto, restringir indicadores estratégicos, como por exemplo a ocupação de leitos de UTI é um procedimento operacionalmente recomendado para evitar sobrecargas em semanas específicas do horizonte de análise. Inclusive, os elevados valores de escassez de leitos e as mortes a ela atribuídas, mostrados nos Gráficos 6, 7 e 8, foram os principais

motivadores para testar um cenário opcional, o cenário 2, de modo a evitar uma situação degradante e que resulta em impactos diretos e indiretos sobre a saúde da população e de trabalhadores da saúde que atuam na linha de frente em resposta à pandemia. A Fiocruz (2021) ainda indica que os danos causados pela doença decorrentes das altas taxas de ocupação de leitos vão além dos óbitos diretos e indiretos observados, implicando em grave desassistência de saúde pública, causando sequelas e gerando um passivo de atendimento extremamente elevado.

Conforme mencionado no início do Capítulo 3, os compartimentos do modelo epidêmico são mutuamente exclusivos, ou seja, um indivíduo pertencente à população só pode estar em um compartimento em cada período de tempo considerado. Então, buscou-se verificar se a soma dos compartimentos de suscetíveis, infectados, críticos, recuperados e mortos a cada período de tempo era igual à população total para todo o horizonte de planejamento, o que foi confirmado.

Adicionalmente, buscou-se fazer uma comparação dos resultados obtidos com o modelo matemático e com o que foi presenciado no Brasil. Utilizando dados do Painel Conass Covid-19 divulgados por semana epidemiológica (CONASS, 2020) e considerando como data inicial 29 de março de 2020 (início da semana epidemiológica 14) e data final 27 de junho de 2020 (início da semana epidemiológica 27), que são as 13 semanas adotadas como horizonte de planejamento, foi possível comparar algumas variáveis de estado epidêmico, como o número de infectados e mortos.

Observa-se que o número de casos acumulados obtidos pelo modelo ao final do horizonte de planejamento, que foi de 2.463.528, é bastante superior ao que foi notificado no país, de 1.313.667 casos acumulados até a semana epidemiológica 26. Contudo, esta diferença pode ser explicada devido aos altos níveis de subnotificação de casos no país relatados por Prado *et al.* (2020) e à adoção no modelo de um número de infecções iniciais 11 vezes maior para o parâmetro I_{k1} do que o divulgado em dados oficiais.

Já o número total de óbitos mostrou-se aproximado, pois segundo o modelo 57.554 indivíduos morrem, enquanto de acordo com os dados oficiais um total de 57.070 mortes foram registradas até a semana epidemiológica 26. Este valor elevado obtido pelo modelo pode ser atribuído a duas principais razões. Primeiro, à premissa adotada de que a escassez de leitos de UTI necessariamente leva o indivíduo à morte (cerca de 60% das mortes estão vinculadas a essa premissa), o que nem sempre pode ocorrer na prática. Segundo, diversas ações adicionais foram tomadas na

realidade, porém não são contabilizadas neste modelo, tais como a expansão da capacidade de assistência de saúde, a recomendação e implementação de outras INF (por exemplo, o uso de máscaras faciais e uma comunicação de risco eficiente por parte de alguns estados e municípios), ou a injeção de recursos na economia por meio de pacotes fiscais do governo (por exemplo, o pagamento do auxílio emergencial a partir de abril de 2020 (BRASIL, 2020g) para pessoas em situação de vulnerabilidade econômica).

Buscou-se também comparar as decisões relacionadas às INF, usando os dados do *Stringency Index* (MATHIEU *et al.*, 2020) para o país e para o período. Enquanto o modelo sugeriu a adoção de INF mais severas no início do horizonte de planejamento para diversas UF, o que ocorreu na prática no Brasil foi o inverso. Devido ao atraso e à falta de coordenação nas recomendações de fechamento, as decisões tornaram-se mais severas apenas em meados de maio de 2020, justamente quando o modelo matemático já começava a flexibilizar as decisões (semana 9), conforme mostrado na Figura 5. Novamente, é importante ressaltar que as decisões de flexibilização do modelo ao final do cenário são influenciadas pelo fato de não existir uma visão preditiva que leve em consideração as semanas seguintes à finalização do cenário de análise, fato que pode vir a ser aprimorado em futuros desenvolvimentos.

4.2.2 Resultados para os cenários 1 e 2

O cenário 1 é composto pelas Equações (1) e (54) a (98), listadas no Apêndice B, às quais incluíram-se as Equações (30) a (33), da subseção 3.3.2. O modelo resultante possui 13.743 variáveis, das quais 4.914 são binárias e 8.829 são contínuas, além de 28.188 restrições. A dimensão do modelo variou consideravelmente em relação ao cenário base e o tempo computacional até a obtenção da solução ótima foi de aproximadamente 100 segundos.

Para o cenário 1, o valor minimizado obtido para a função objetivo foi de 4.066.407,92 Anos de Vida Perdidos por causa da COVID-19 para todo o Brasil. O valor é 0,3% superior ao obtido para o cenário base. A parcela epidêmica contribuiu com aproximadamente 17% deste valor e a parcela econômica com 83%.

A Tabela 3 apresenta por UF os principais resultados para o cenário 1, incluindo os AVP para as parcelas epidêmica e econômica, além do número

acumulado de infectados e de mortos ao final do horizonte de planejamento e as respectivas variações em relação ao cenário base.

Tabela 3 – Principais resultados para o cenário 1

UF	AVP		Infectados		Mortos	
	Parcela epidêmica	Parcela econômica	Nº	Variação	Nº	Variação
AC	895	41.961	4.322	-3,8%	65	-6,5%
AL	7.253	41.976	28.437	0,0%	570	0,0%
AP	2.197	13.444	6.236	2,9%	151	4,4%
AM	5.588	117.194	23.919	-0,3%	447	-0,9%
BA	39.357	327.277	144.719	0,0%	3.195	0,0%
CE	9.774	374.136	57.826	-8,0%	902	-11,2%
DF	7.156	16.896	27.959	3,3%	596	8,7%
ES	10.314	50.856	51.491	-7,3%	889	-6,5%
GO	36.795	103.244	101.994	-8,0%	3.101	-12,3%
MA	11.645	82.223	46.294	0,0%	1.026	0,0%
MT	11.039	23.792	36.887	-4,7%	788	-6,7%
MS	7.834	33.801	27.838	-4,6%	672	-5,9%
MG	113.628	289.101	373.372	5,3%	10.853	7,8%
PA	10.158	74.447	53.261	0,0%	819	0,0%
PB	19.791	38.349	54.847	0,0%	1.649	0,0%
PR	47.509	167.148	148.797	-4,5%	4.195	-5,7%
PE	21.864	167.206	108.438	0,0%	1.883	0,0%
PI	6.917	46.099	32.806	3,4%	613	6,9%
RJ	31.635	164.266	169.270	-5,0%	2.793	-8,7%
RN	7.588	75.428	37.143	1,9%	638	2,1%
RS	51.696	193.266	171.288	-5,8%	5.041	-8,6%
RO	7.104	21.643	20.975	0,0%	488	0,0%
RR	1.400	6.920	4.003	4,4%	91	7,0%
SC	35.042	135.131	114.866	8,2%	3.249	14,3%
SP	153.353	744.597	616.158	10,6%	13.524	20,3%
SE	7.526	26.092	23.128	-4,6%	565	-6,2%
TO	7.823	17.034	18.750	5,3%	641	6,9%
Brasil	672.883	3.393.525	2.505.026	1,7%	59.442	3,3%

Fonte: Autoria própria (2023).

Com a adição de restrições que estabelecem um tempo mínimo entre as trocas de níveis de INF, o modelo tem a sua flexibilidade de decisão reduzida, o que resulta em 1,7% mais infecções e 3,3% mais mortes no Brasil em comparação com o cenário base. Porém, pode-se observar a partir da Tabela 3 que algumas UF apresentaram uma variação negativa no número de infectados e de mortos, enquanto que para outras as variações foram positivas. Do ponto de vista de gestão, contudo, a estabilidade das decisões de INF por um período de duas semanas se mostra aderente às necessidades operacionais. O modelo proposto traz, assim, um contexto matemático que viabiliza a análise da referida condição operacional, se esta for uma opção necessariamente demandada no contexto de gestão.

Já o cenário 2 é constituído pelas Equações (1) e (54) a (98), listadas no Apêndice B, e pela Equação (34), conforme exposto na subsecção 3.3.3. O modelo resultante para o cenário 2 possui 11.988 variáveis, das quais 3.159 são binárias e 8.829 são variáveis contínuas, além de 23.544 restrições. O tempo computacional até a obtenção da solução ótima foi de aproximadamente 20 segundos.

Para o cenário 2, o valor minimizado obtido para a função objetivo foi de 7.726.200,04 AVP por causa da COVID-19 para todo o Brasil, aproximadamente 90% maior do que o obtido para o cenário base. A parcela epidêmica contribuiu com aproximadamente 1,3% deste valor, enquanto que a parcela econômica com 98,7%.

A Tabela 4 informa os principais resultados por UF para o cenário 2, incluindo os AVP para as parcelas epidêmica e econômica, além do número acumulado de infectados e de mortos ao final das 13 semanas e as respectivas variações em relação ao cenário base.

Tabela 4 – Principais resultados para o cenário 2


UF	AVP		Infectados		Mortos	
	Parcela epidêmica	Parcela econômica	Nº	Variação	Nº	Variação
AC	678	63.194	2.012	-55,2%	49	-29,2%
AL	352	152.970	1.127	-96,0%	28	-95,2%
AP	115	38.555	358	-94,1%	8	-94,6%
AM	3.097	142.185	12.777	-46,7%	248	-45,0%
BA	3.112	879.023	10.302	-92,9%	253	-92,1%
CE	8.359	395.654	48.608	-22,7%	772	-24,0%
DF	6.146	18.517	23.283	-13,9%	512	-6,6%
ES	1.213	122.458	4.547	-91,8%	105	-89,0%
GO	2.834	201.809	20.599	-81,4%	240	-93,2%
MA	525	264.650	3.708	-92,0%	46	-95,5%
MT	359	108.904	1.046	-97,3%	26	-97,0%
MS	713	76.091	2.776	-90,5%	61	-91,4%
MG	4.236	991.084	16.500	-95,3%	405	-96,0%
PA	416	394.230	1.368	-97,4%	34	-95,9%
PB	332	228.319	1.127	-97,9%	28	-98,3%
PR	2.974	448.430	11.123	-92,9%	264	-94,1%
PE	1.562	542.156	5.473	-95,0%	139	-92,6%
PI	245	211.022	885	-97,2%	23	-96,0%
RJ	18.821	186.526	112.776	-36,7%	1.667	-45,5%
RN	2.776	93.537	20.216	-44,5%	233	-62,6%
RS	6.048	310.064	41.190	-77,4%	591	-89,3%
RO	173	118.903	483	-97,7%	12	-97,6%
RR	455	8.723	1.915	-50,0%	30	-65,2%
SC	5.184	203.072	31.819	-70,0%	481	-83,1%
SP	31.662	1.284.884	125.909	-77,4%	2.859	-74,6%
SE	421	77.613	1.338	-94,5%	32	-94,8%
TO	217	60.602	753	-95,8%	18	-97,0%
Brasil	103.024	7.623.176	504.020	-79,5%	9.161	-84,1%

Fonte: Autoria própria (2023).

Conforme a Tabela 4, em comparação com o cenário base, são registrados 79,5% menos infectados e 84,1% menos mortos no Brasil para o cenário 2. Como o modelo do cenário 2 não permite escassez de leitos de UTI, fato alinhado às recomendações colocadas em Fiocruz (2021, p. 5), as INF adotadas são muito mais rigorosas e, conseqüentemente, menos indivíduos se infectam e morrem, resultando em AVP epidêmicos cerca de 6 vezes menor quando comparado ao cenário base. Conseqüentemente, em decorrência das medidas mais restritivas, a parcela econômica torna-se predominante e os AVP econômicos mais que dobram.

A Figura 6 ilustra o resultado para as decisões relacionadas às INF por UF para ambos os cenários adicionais.

Figura 6 – Decisões de INF por UF para os cenários 1 e 2



Fonte: Autoria própria (2023).

Com base nas Figuras 5 e 6, observou-se que as sequências ótimas de INF para os três cenários são distintas. No cenário 1, pode-se constatar uma mudança mais abrupta para INF de menor seriedade ao final do horizonte de planejamento em relação ao cenário base. Por exemplo, Acre (AC), Mato Grosso (MT), Mato Grosso do Sul (MS), Paraná (PR), Santa Catarina (SC) e Sergipe (SE) passam diretamente da INF nível 3 para o nível 1. Para o Amazonas (AM) a transição ocorre do nível 4 diretamente para o nível 1, já no Rio de Janeiro (RJ), do nível 5 para o 3.

No cenário 2, há a indicação da INF nível 5 para todas as UF em maior número e por períodos de tempo mais longos, de modo a não ultrapassar a taxa de ocupação de leitos de UTI que foi estabelecida. Assim, as decisões de INF são muito mais rigorosas, preservando vidas, porém aumentando os AVP econômicos.

De modo geral, percebe-se que os resultados registrados para o cenário 1 não apresentam diferenças significativas em comparação ao cenário base. Por outro lado, o cenário 2 apresenta resultados completamente distintos. No cenário base o respeito à taxa máxima de ocupação de leitos de UTI não constitui uma restrição. Some-se a este fato o já comentado caráter de não preditividade do modelo no cenário base para as semanas que seguem o final do horizonte de análise e, assim, geram-se decisões de INF menos severas ao longo do horizonte. Já os resultados do cenário 2 possuem um maior alinhamento às recomendações dadas em Fiocruz (2021), considerando as necessidades práticas para um controle mais efetivo da pandemia em contextos maiores que o horizonte de análise, ainda que exista um aumento que se observa no indicador AVP.

4.3 Análise de sensibilidade

Devido à elevada incerteza dos modelos epidêmicos e de seus parâmetros, é comum que os estudos neste tema realizem análises de sensibilidade, conforme constatado na revisão sistemática da literatura e apontado no Quadro 2. Análises de sensibilidade normalmente são conduzidas para determinar como mudanças nos dados e nas escolhas metodológicas afetam os resultados.

Desse modo, utilizando o modelo considerado no cenário base, foram realizadas análises de sensibilidade para dois parâmetros: ΔPIB_{ki} e α_i . A opção por realizar a análise de sensibilidade destes parâmetros deu-se justamente devido ao alto grau de incerteza em relação aos valores do impacto econômico e de saúde relacionados às INF.

Para determinar a sensibilidade relacionada aos valores do impacto econômico das INF, variou-se o parâmetro ΔPIB_{ki} em um intervalo de [-20%, +20%] dos valores estimados. A Tabela 5 informa os resultados obtidos para a função objetivo em AVP, o número de infectados e de mortos, o nível de INF médio indicado pelo modelo e as respectivas variações em relação ao valor efetivamente adotado para o parâmetro.

Tabela 5 – Análise de sensibilidade do parâmetro ΔPIB_{ki}

ΔPIB_{ki}	AVP		Infectados		Mortos		Nível de INF médio
	Nº	Variação	Nº	Variação	Nº	Variação	
-20%	3.363.461,91	-17,1%	2.222.508	-9,8%	48.218	-16,2%	3,00
-10%	3.712.606,04	-8,5%	2.334.590	-5,2%	52.384	-9,0%	2,98
-5%	3.885.132,68	-4,2%	2.383.566	-3,2%	54.529	-5,3%	2,97
-1%	4.022.137,65	-0,8%	2.441.383	-0,9%	56.766	-1,4%	2,96
0%	4.056.237,87	0%	2.463.528	0	57.554	0%	2,96
+1%	4.090.292,72	0,8%	2.463.528	0%	57.554	0%	2,96
+5%	4.225.798,22	4,2%	2.546.027	3,3%	60.845	5,7%	2,95
+10%	4.393.815,25	8,3%	2.601.797	5,6%	63.315	10,0%	2,94
+20%	4.726.226,05	16,5%	2.698.518	9,5%	67283,13	16,9%	2,92

Fonte: Autoria própria (2023).

Quando há uma variação negativa no ΔPIB_{ki} , o modelo permite INF mais severas, pois o impacto econômico dessas decisões é menor, o que resulta na diminuição de infectados e mortos e um valor menor para a função objetivo, ou seja, menos AVP. Já quando a variação no ΔPIB_{ki} é positiva, ocorre o contrário. Por exemplo, uma variação de +20% no ΔPIB_{ki} ocasiona uma variação de 16,5% no valor da função objetivo, de 9,5% no número de infectados e de 16,9% no número de mortos, além de reduzir o nível de INF médio em 0,04.

A partir da análise da Tabela 5, e tendo por base o indicador nível de INF médio, conclui-se que as variações testadas no parâmetro ΔPIB_{ki} não geraram alterações no nível de INF médio superiores à 1,35%. Assim, o modelo se mostra relativamente estável frente às variações deste parâmetro.

Também realizou-se uma análise de sensibilidade do parâmetro α_i , que indica a redução na taxa de transmissão da doença por nível de INF adotado, variando-o em um intervalo [-4%, +4%] dos valores estimados, conforme apresentado na Tabela 6.

Tabela 6 – Análise de sensibilidade do parâmetro α_i

α_i	AVP		Infectados		Mortos		Nível de INF médio
	Nº	Variação	Nº	Variação	Nº	Variação	
-4%	4.300.569,66	6,0%	2.570.888	4,4%	62.332	8,3%	3,03
-2%	4.172.156,60	2,9%	2.534.537	2,9%	60.413	5,0%	3,00
-1%	4.109.071,08	1,3%	2.502.808	1,6%	59.183	2,8%	2,97
0%	4.056.237,87	0%	2.463.528	0%	57.554	0%	2,96
+1%	3.997.213,64	-1,5%	2.481.405	0,7%	58.267	1,2%	2,93
+2%	3.945.454,87	-2,7%	2.426.911	-1,5%	55.951	-2,8%	2,91
+4%	3.845.227,05	-5,2%	2.370.214	-3,8%	53.718	-6,7%	2,87

Fonte: Autoria própria (2023).

Ao variar o parâmetro α_i negativamente, ou seja, tornar as INF menos eficazes na redução da taxa de transmissão, percebe-se um aumento no número de infectados e de mortos, um maior nível de INF médio e um valor maior para a função objetivo, em AVP. Quando há uma variação positiva em α_i , observa-se uma tendência de diminuição nos AVP resultantes da função objetivo, bem como na severidade das decisões relativas às INF, já que estas ficam mais eficientes na contenção da doença. Além disso, o número de infectados e mortos também apresenta variações negativas, exceto para a variação de +1%. Essa exceção pode ser explicada por uma redução mais acentuada no nível de INF médio, possivelmente influenciada pela parte econômica da função objetivo, o que leva a um aumento nos dois indicadores mencionados. Em outras palavras, o acréscimo de 1% na eficácia das INF não foi suficiente para compensar a alteração nas decisões referentes à variável x_{kit} , para reduzir o número de infectados e, por conseguinte, de mortos.

Com base na análise da Tabela 6 e considerando o indicador nível de INF médio como referência, observa-se que as variações testadas no parâmetro α_i não resultaram em alterações superiores a 3,04% no nível de INF médio. Portanto, o modelo demonstra relativa estabilidade nas decisões diante das variações testadas para tal parâmetro.

Por fim, com o aprimoramento do modelo matemático e a sua aplicação em um estudo de caso envolvendo a pandemia de COVID-19 nas 27 UF do Brasil, foram gerados resultados para diferentes cenários e a estabilidade das respostas obtidas foi testada por meio de variações em parâmetros-chave do modelo. Os resultados apresentados neste capítulo para os diversos cenários podem proporcionar percepções gerenciais importantes para os formuladores de políticas, considerando os impactos potenciais na saúde humana decorrentes de eventos epidêmicos.

Na sequência, o Capítulo 5 apresenta as considerações finais desta dissertação, além elencar algumas das limitações deste estudo e fornecer sugestões para trabalhos futuros.

5 CONSIDERAÇÕES FINAIS

As enormes perdas humanas e econômicas ocasionadas pela pandemia de COVID-19 são evidentes e inegáveis. Neste trabalho, buscou-se contabilizar essas perdas humanas e econômicas sob uma mesma métrica, de AVP, a qual reflete os impactos potenciais na saúde humana. Além disso, levando em conta que na fase inicial da pandemia, com a ausência de medicamentos e vacinas, as INF foram o principal instrumento de mitigação e supressão da doença, decidiu-se por considerá-las neste estudo de modo a auxiliar na tomada de decisão dos formuladores de políticas, sugerindo um portfólio de intervenções a ser adotado.

Assim, buscou-se desenvolver e testar um modelo matemático para minimizar os AVP durante eventos epidêmicos, que considera a adoção de INF e os seus efeitos na economia. Para isso, foi conduzida uma revisão sistemática da literatura apoiada na declaração PRISMA, a fim de identificar modelos matemáticos que servissem como base para o desenvolvimento do modelo proposto neste estudo. Com a definição do portfólio bibliográfico e a análise dos artigos, o modelo matemático formulado por Biswas e Alfandari (2022) mostrou-se o mais adequado por reunir diversas características desejáveis aos objetivos deste trabalho.

O modelo de otimização foi formulado inicialmente como uma Programação Não Linear Inteira Mista (PNLIM), cuja função objetivo minimiza os AVP de uma população, decorrentes tanto das perdas humanas quanto das perdas econômicas causadas pela COVID-19. O modelo proposto também determina a alocação ideal de INF, captura a progressão da epidemia e considera as capacidades de recursos de saúde, incluindo médicos, leitos de UTI e leitos regulares. Em seguida, o modelo desenvolvido foi transformado em um modelo de Programação Linear Inteira Mista (PLIM), por meio da linearização dos termos quadráticos. Ainda, foram definidos dois cenários adicionais ao cenário base, um com foco na viabilidade de gestão das decisões e outro com foco na capacidade de leitos de UTI.

Demonstrou-se a utilização do modelo empregando-o em um estudo de caso envolvendo o estágio inicial da pandemia de COVID-19 nas 27 UF do Brasil. Os dados utilizados na aplicação do modelo foram coletados para a realidade brasileira a partir de órgãos governamentais e da literatura sobre a COVID-19. Os resultados indicam que o cenário base apresentou o menor valor para a função objetivo em AVP, porém foi registrada uma considerável sobrecarga no sistema de saúde, inclusive com a

escassez de leitos de UTI sendo responsável por cerca de 60% das mortes. Ao testar cenários opcionais adicionando restrições ao modelo utilizado no cenário base, foi observado um aumento nos valores da função objetivo, o que era esperado, uma vez que o modelo perde flexibilidade. O cenário 1, que apresenta um foco gerencial das INF, retornou um valor 0,3% maior para a função objetivo, porém os resultados registrados não apresentaram diferenças significativas em relação ao cenário base.

Já o cenário 2, que leva em consideração o risco atrelado às altas taxas de ocupação de leitos de UTI, retornou um valor de AVP aproximadamente 90% maior para a função objetivo do que o obtido no cenário base, sugerindo níveis de INF muito mais severos por períodos mais longos para todas as UF, porém apresentando um melhor controle da disseminação da doença, sem registrar escassez de recursos de saúde e mortes atreladas a ela. Com base nos resultados obtidos para os cenários avaliados e considerando as orientações propostas em Fiocruz (2021), há uma tendência de que as decisões sugeridas para o cenário 2 sejam as mais adequadas, ainda que este cenário tenha retornado um maior valor em AVP para a função objetivo. Ademais, para os três cenários considerados, a parcela econômica da função objetivo foi predominante no valor total de AVP.

Além disso, conduziu-se uma análise de sensibilidade para avaliar a sensibilidade dos parâmetros ΔPIB_{ki} e α_i , a qual foi motivada pelo considerável grau de incerteza em relação aos valores do impacto econômico e de saúde associados às INF. Desta forma, o estudo atingiu os objetivos propostos inicialmente e elencados no Capítulo 1.

Embora a dinâmica da doença esteja em constante evolução e haja incertezas derivadas da falta de precisão dos parâmetros adotados no modelo e pela falta de precisão do modelo de Norris (2006), os resultados podem fornecer um direcionamento para os responsáveis pela tomada de decisões em estágios relativamente precoces da epidemia, especialmente no Brasil, sobre como implementar um portfólio de INF considerando o impacto de suas decisões tanto na saúde quanto na economia, de modo a minimizar os AVP da população, indicador que reflete os impactos potenciais na saúde humana. O modelo e as análises feitas podem ser úteis não apenas para o caso da COVID-19, mas também para o gerenciamento de futuras ocorrências epidêmicas.

Em termos de limitações deste trabalho, podem-se citar o uso de um modelo compartimental epidêmico, que faz uma simplificação da realidade, que assume uma

população homogênea e totalmente misturada e que desconsidera as particularidades nos contatos entre os indivíduos, conforme apontado por Dimitrov e Meyers (2010, p. 8).

Além disso, este estudo se limita a analisar apenas a mortalidade prematura, por meio do indicador AVP. Entretanto é importante ressaltar que uma avaliação abrangente do impacto na saúde deve levar em consideração o ônus da incapacidade relacionada à doença, o que requer um profundo conhecimento das sequelas associadas à COVID-19 e sua prevalência, porém os dados disponíveis atualmente ainda são limitados.

Também é importante considerar diversas precauções em relação ao método proposto por Norris (2006) e utilizado para compor a parcela econômica do modelo, conforme mencionado pelo próprio autor. Apesar de haver uma correlação positiva significativa entre o PIB *per capita* e a expectativa de vida, essa relação ocorre sobretudo por meio do impacto do PIB na renda dos menos favorecidos e nos gastos públicos. Assim, um acréscimo na produção econômica de um local não necessariamente reflete em impactos positivos sobre a pobreza de renda e o investimento público, e conseqüentemente na saúde humana. O alívio da pobreza exige que os benefícios salariais e de emprego sejam estendidos às pessoas que estão em condições socioeconômicas desfavoráveis, enquanto que o aumento das receitas fiscais do governo pode melhorar a saúde da população caso esse aumento seja convertido em investimentos públicos adicionais voltados, principalmente, à promoção da saúde. Adicionalmente, existe a questão pertinente de avaliar se as alterações em medidas agregadas, como a renda total ou a expectativa de vida média, são indicadores apropriados (NORRIS, 2006).

Além disso, o modelo de Norris (2006) pode fornecer estimativas menos precisas para as UF que se encontram à direita na curva de Preston apresentada no Gráfico 1. Para as UF com menores PIB *per capita* a influência do crescimento econômico na expectativa de vida é mais acentuada, ao passo que para as UF com maiores PIB *per capita* esse impacto torna-se menos significativo. Em resumo, o crescimento econômico desempenha um papel mais poderoso na obtenção de benefícios para a saúde quando ocorre em regiões de baixa renda (NORRIS, 2006; FESCHET *et al.*, 2013).

Uma outra limitação relevante a ser mencionada é a existência de um intervalo de tempo entre uma variação observada na renda e os efeitos potenciais na saúde,

conforme mencionado por Feschet *et al.* (2013) e Wu *et al.* (2015). Isso indica que os impactos potenciais na saúde humana, em AVP, resultantes da parcela econômica ocorrem ao longo do tempo, em contraste com os impactos decorrentes da parcela epidêmica, em AVP, que são imediatamente contabilizados após os óbitos ocorrerem. Desta forma, uma maior análise da necessidade de ponderação nas parcelas social e econômica que fazem parte da função objetivo, Equação (1), pode ser objeto de futuros desenvolvimentos.

Ainda com a finalidade de aprimorar o modelo matemático e superar as limitações identificadas durante o desenvolvimento deste estudo, propõe-se como sugestões para pesquisas futuras a utilização de indicadores mais completos para quantificar os impactos na saúde, como os *Disability Adjusted Life Years* (DALY) ou Anos de Vida Ajustados por Incapacidade (AVAI), o qual é constituído pela soma dos Anos de Vida Perdidos (AVP) com os Anos Vividos com Incapacidade (AVI), quando houver disponibilidade de dados para a COVID-19 para este último.

Também pode-se buscar utilizar outras métricas que melhor representem a renda real para tratar a parcela econômica, em vez do PIB. Alternativamente, também é válido considerar a inclusão dos gastos públicos realizados pelo governo, buscando amenizar os efeitos econômicos contracionistas da COVID-19 no Brasil. Nesse contexto, poderiam ser utilizados os resultados obtidos por Porsse *et al.* (2020), que ao analisar um cenário alternativo em seu estudo, considerou as medidas de estímulo fiscal do governo para mitigar parcialmente a redução do PIB projetada sob o surto de COVID-19.

Além disso, o modelo pode ser ampliado de diversas formas, de modo a expandir o modelo compartimental epidêmico, incluir novas restrições e testar cenários distintos. Por exemplo, é possível adaptar o modelo para permitir a expansão de capacidade de recursos médicos ao longo do tempo, ou a transferência de recursos e de pacientes entre as UF que compartilham fronteira, com base na oferta e na demanda de recursos. Pode-se utilizar parâmetros epidêmicos variáveis no tempo conforme a evolução da doença, além de considerar um horizonte de planejamento maior, com reinfecções e a inclusão de vacinas. Também pode ser adotado o conceito de horizonte rolante, normalmente utilizado em problemas de *scheduling*, em que somente a programação para os períodos imediatos é implementada, para a obtenção de respostas operacionalmente mais adequadas para o término de cenários.

Por fim, é possível adaptar o modelo para estudar outras doenças com potencial epidêmico, como por exemplo a dengue, uma doença causada por um vírus transmitido pelo mosquito *Aedes aegypti* (BRASIL, 2023), que vem se tornando cada vez mais prevalente nas Américas e, principalmente no Brasil.

REFERÊNCIAS

- ACEMOGLU, Daron *et al.* Optimal targeted lockdowns in a multigroup SIR model. **American Economic Review: Insights**, v. 3, n. 4, p. 487-502, 2021.
- AGARWAL, Ruchir *et al.* **A global strategy to manage the long-term risks of COVID-19**. Washington, DC: International Monetary Fund, 2022. 25 p. (IMF Working Papers Series, 2022/068). ISBN 9798400205996. DOI: 10.5089/9798400205996.001.A001. Disponível em: <https://www.imf.org/en/Publications/WP/Issues/2022/04/04/A-Global-Strategy-to-Manage-the-Long-Term-Risks-of-COVID-19-516079>. Acesso em: 26 jul. 2023.
- AKHTAR, Muhammad U. *et al.* N-RAND: An efficient and robust dismantling approach for infectious disease network. **Information Processing & Management**, v. 60, n. 2, p. 103221, 2023.
- ALVAREZ, Fernando; ARGENTE, David; LIPPI, Francesco. A simple planning problem for COVID-19 lock-down, testing, and tracing. **American Economic Review: Insights**, v. 3, n. 3, p. 367-82, 2021.
- ANTUNES, Bianca B. de P. *et al.* Progressão dos casos confirmados de COVID-19 após implantação de medidas de controle. **Revista Brasileira de Terapia Intensiva**, v. 32, n. 2, p. 213-223, 2020.
- BARBATO, Michele; CESELLI, Alberto; PREMOLI, Marco. On the impact of resource relocation in facing health emergencies. **European Journal of Operational Research**, 2022.
- BARLOW, M. T.; MARSHALL, N. D.; TYSON, R. C. Optimal shutdown strategies for COVID-19 with economic and mortality costs: British Columbia as a case study. **Royal Society Open Science**, v. 8, n. 9, p. 202255, 2021.
- BAYRAKTAR, Erhan; COHEN, Asaf; NELLIS, April. A macroeconomic SIR model for COVID-19. **Mathematics**, v. 9, n. 16, p. 1901, 2021.
- BENDAVID, Eran *et al.* Assessing mandatory stay-at-home and business closure effects on the spread of COVID-19. **European Journal of Clinical Investigation**, v. 51, n. 4, p. e13484, 2021.
- BERTSIMAS, Dimitris *et al.* Where to locate COVID-19 mass vaccination facilities?. **Naval Research Logistics (NRL)**, v. 69, n. 2, p. 179-200, 2022.
- BISPO JÚNIOR, José P.; SANTOS, Djanilson B. dos. COVID-19 como síndrome: modelo teórico e fundamentos para a abordagem abrangente em saúde. **Cadernos de Saúde Pública**, v. 37, p. e00119021, 2021.
- BISWAS, Debajyoti; ALFANDARI, Laurent. Designing an optimal sequence of non-pharmaceutical interventions for controlling COVID-19. **European Journal of Operational Research**, v. 303, n. 3, p. 1372-1391, 2022.

BONATTO, Célia P. P. **Análise espacial dos anos potenciais de vida perdidos por causas externas no estado de São Paulo 2000 e 2010**. 2013. 186 f. Tese (Doutorado em Saúde Pública) – Programa de Pós-Graduação em Saúde Coletiva, Faculdade de Medicina de Botucatu, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2013.

BRANDÃO, Mauricio P. Complex scenarios with competing factors. **Nonlinear Dynamics**, v. 104, n. 3, p. 2961-2975, 2021.

BRASIL. Supremo Tribunal Federal. **Referendada decisão que garante a estados, DF e municípios liberdade na adoção de medidas contra pandemia**. Brasília, DF: Superior Tribunal de Federal, 2020a. Disponível em: <https://portal.stf.jus.br/noticias/verNoticiaDetalhe.asp?idConteudo=453547&ori=1>. Acesso em: 26 jul. 2023.

BRASIL. Ministério da Saúde. Cadastro Nacional dos Estabelecimentos de Saúde do Brasil (CNES). Nota: CNES - RECURSOS FÍSICOS - HOSPITALAR - LEITOS DE INTERNAÇÃO - BRASIL. *In*: DATASUS. **Quantidade existente de leitos de internação segundo região/UF**. jun. 2020b. Disponível em: <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/leiintbr.def>. Acesso em: 26 jul. 2023.

BRASIL. Ministério da Saúde. Cadastro Nacional dos Estabelecimentos de Saúde do Brasil – CNES. Nota: CNES - RECURSOS FÍSICOS - HOSPITALAR - LEITOS COMPLEMENTARES - BRASIL. *In*: DATASUS. **Quantidade existente por leitos complementares segundo região/UF**. jun. 2020c. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?cnes/cnv/leiutibr.def>. Acesso em: 26 jul. 2023.

BRASIL. Ministério da Saúde. Sistema de Informações sobre Mortalidade – SIM. Nota: MORTALIDADE - BRASIL. *In*: DATASUS. **Óbitos por ocorrência por unidade da federação segundo faixa etária**. 2020d. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sim/cnv/obt10uf.def>. Acesso em: 26 jul. 2023.

BRASIL. Ministério da Saúde. Conselho Nacional de Saúde (CNS). **Recomendação nº 036, de 11 de maio de 2020**. Brasília, DF: Conselho Nacional de Saúde, 2020e. Disponível em: <http://conselho.saude.gov.br/images/Recomendacoes/2020/Reco036.pdf>. Acesso em: 26 jul. 2023.

BRASIL. Senado Federal. **Projeto de Lei nº 2.033, de 20 de abril de 2020**. Dispõe sobre a indenização e a pensão por lucros cessantes cabíveis em decorrência de óbitos por ausência de leitos de UTI [...]. Brasília, DF: Senado Federal, 2020f. Disponível em: https://www25.senado.leg.br/web/atividade/materias/-/materia/141646?_gl=1*18ycsx*_ga*NjMwNjIwMTg3LjE2ODc4ODYzNjU.*_ga_CW3ZH25XMK*MTY4Nzg4NjM2NS4xLjAuMTY4Nzg4NjM2NS4wLjAuMA. Acesso em: 26 jul. 2023.

- BRASIL. Senado Federal. Agência Senado. **Aprovado pelo Congresso, auxílio emergencial deu dignidade a cidadãos durante a pandemia**. Brasília, DF: Senado Federal, 2020g. Disponível em: <https://www12.senado.leg.br/noticias/materias/2020/12/30/aprovado-pelo-congresso-auxilio-emergencial-deu-dignidade-a-cidadaos-durante-a-pandemia>. Acesso em: 26 jul. 2023.
- BRASIL. Ministério da Saúde. **Dengue**. 2023. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/d/dengue>. Acesso em: 26 jul. 2023.
- BRAUNER, Jan M. *et al.* Inferring the effectiveness of government interventions against COVID-19. **Science**, v. 371, n. 6531, p. eabd9338, 2021.
- BÜYÜKTAHTAKIN, İ. Esra; DES-BORDES, Emmanuel; KIBIŞ, Eyyüb Y. A new epidemics-logistics model: Insights into controlling the Ebola virus disease in West Africa. **European Journal of Operational Research**, v. 265, n. 3, p. 1046-1063, 2018.
- CANABARRO, Askery *et al.* Data-driven study of the COVID-19 pandemic via age-structured modelling and prediction of the health system failure in Brazil amid diverse intervention strategies. **PloS One**, v. 15, n. 7, p. e0236310, 2020.
- CANDEL, Francisco J. *et al.* Social restrictions versus testing campaigns in the COVID-19 crisis: a predictive model based on the Spanish case. **Viruses**, v. 13, n. 5, p. 917, 2021.
- CENTERS FOR DISEASE CONTROL AND PREVENTION (CDC). **Nonpharmaceutical Interventions (NPIs)**. 2020. Disponível em: <https://www.cdc.gov/nonpharmaceutical-interventions/index.html>. Acesso em: 26 jul. 2023.
- CHAN, Louis Y. H.; YUAN, Baoyin; CONVERTINO, Matteo. COVID-19 non-pharmaceutical intervention portfolio effectiveness and risk communication predominance. **Scientific Reports**, [s. l.], v. 11, n. 1, p. 1-17, 2021.
- CHARPENTIER, Arthur *et al.* COVID-19 pandemic control: balancing detection policy and lockdown intervention under ICU sustainability. **Mathematical Modelling of Natural Phenomena**, v. 15, n. 57, p. 1-42, 2020.
- CHEN, Victoria C. P. *et al.* An optimization framework to study the balance between expected fatalities due to COVID-19 and the reopening of US communities. **IEEE Transactions on Automation Science and Engineering**, v. 19, n. 2, p. 586-602, 2021.
- CHOWDHURY, Rajiv *et al.* Dynamic interventions to control COVID-19 pandemic: a multivariate prediction modelling study comparing 16 worldwide countries. **European Journal of Epidemiology**, v. 35, n. 5, p. 389-399, 2020.

CONSELHO FEDERAL DE MEDICINA (CFM). Conselho Federal de Medicina. Resolução nº 2.271, de 14 de fevereiro de 2020. Define as unidades de terapia intensiva e unidades de cuidado intermediário conforme sua complexidade e nível de cuidado, determinando a responsabilidade técnica médica. **Diário Oficial da União**: seção 1, Brasília, DF, ano 144, n. 77, p. 90, 14 fev. 2020.

CONSELHO NACIONAL DE SECRETÁRIOS DE SAÚDE (CONASS). **Painel Conass COVID-19**. 2020. Disponível em: <https://www.conass.org.br/painelconasscovid19/>. Acesso em: 26 jul. 2023.

CORREIA, Sergio; LUCK, Stephan; VERNER, Emil. Pandemics depress the economy, public health interventions do not: Evidence from the 1918 flu. **The Journal of Economic History**, v. 82, n. 4, p. 917-957, 2022.

DAVIES, Nicholas G. *et al.* Effects of non-pharmaceutical interventions on COVID-19 cases, deaths, and demand for hospital services in the UK: a modelling study. **The Lancet Public Health**, v. 5, n. 7, p. e375-e385, 2020.

DENG, Yan; SHEN, Siqian; VOROBAYCHIK, Yevgeniy. Optimization methods for decision making in disease prevention and epidemic control. **Mathematical Biosciences**, v. 246, n. 1, p. 213-227, 2013.

DI DOMENICO, Laura *et al.* Impact of lockdown on COVID-19 epidemic in Île-de-France and possible exit strategies. **BMC Medicine**, v. 18, n. 1, p. 1-13, 2020.

DIMITROV, Nedialko B.; MEYERS, Lauren A. Mathematical approaches to infectious disease prediction and control. **INFORMS Tutorials in Operations Research**, p. 1-25, 2010.

EICHENBAUM, Martin S.; REBELO, Sergio; TRABANDT, Mathias. The macroeconomics of epidemics. **The Review of Financial Studies**, v. 34, n. 11, p. 5149-5187, 2021.

EICHENBAUM, Martin S.; REBELO, Sergio; TRABANDT, Mathias. The macroeconomics of testing and quarantining. **Journal of Economic Dynamics and Control**, v. 138, p. 104337, 2022.

EL MEHDI, Moumine *et al.* Mathematical study aiming at adopting an effective strategy to coexist with coronavirus pandemic. **Journal of Mathematical and Computational Science**, v. 11, n. 1, p. 44-60, 2021.

FARAHANI, Reza Z.; RUIZ, Rubén; VAN WASSENHOVE, Luk N. Introduction to the special issue on the role of operational research in future epidemics/pandemics. **European Journal of Operational Research**, v. 304, n. 1, p. 1-8, 2023.

FERCHIOU, Ahmed *et al.* Individual behaviors and COVID-19 lockdown exit strategy: A mid-term multidimensional bio-economic modeling approach. **Frontiers in Public Health**, v. 8, p. 606371, 2020.

FERGUSON, Neil *et al.* Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand. **Imperial College London**, Londres, v. 10, n. 77482, p. 491-497, 2020.

FESCHET, Pauline *et al.* Social impact assessment in LCA using the Preston pathway. **The International Journal of Life Cycle Assessment**, v. 18, n. 2, p. 490-503, 2013.

FLAXMAN, Seth *et al.* Estimating the effects of non-pharmaceutical interventions on COVID-19 in Europe. **Nature**, v. 584, n. 7820, p. 257-261, 2020.

FRAUENTHAL, James C. **Mathematical modeling in epidemiology**. Springer Science & Business Media, 2012.

FREJ, Eduarda A. *et al.* Decision model for allocation of intensive care unit beds for suspected COVID-19 patients under scarce resources. **Computational and Mathematical Methods in Medicine**, v. 2021, 2021.

FUNDAÇÃO OSWALDO CRUZ (FIOCRUZ). Boletim Observatório Covid-19: **boletim extraordinário**: 16 de março de 2021. Rio de Janeiro: Fiocruz, 2021. 5 p. Edição especial. Disponível em: <https://www.arca.fiocruz.br/handle/icict/46405>. Acesso em: 26 jul. 2023.

FUNDAÇÃO OSWALDO CRUZ (FIOCRUZ). Boletim Observatório Covid-19: **nota técnica**: leitos de UTI para COVID-19: 10 de fevereiro de 2022. Rio de Janeiro: Fiocruz, 2022. 3 p. Disponível em: <https://portal.fiocruz.br/documento/nota-tecnica-leitos-de-uti-para-covid-19>. Acesso em: 26 jul. 2023.

GARDNER, John W.; SANBORN, Jill S. Years of potential life lost (YPLL) — what does it measure?. **Epidemiology**, v. 1, n. 4, p. 322-329, 1990.

GHAMIZI, Salah *et al.* Data-driven simulation and optimization for Covid-19 exit strategies. *In*: KDD '20: The 26th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2020, California. **Proceedings [...]**. New York: Association for Computing Machinery, 2020, p. 3434-3442.

GÖKLER, Mehmet E.; METINTAŞ, Selma. Years of potential life lost and productivity costs due to COVID-19 in Turkey: one yearly evaluation. **Public Health**, v. 203, p. 91-96, 2022.

GOMES, Sebastião C. P.; MONTEIRO, Igor O.; ROCHA, Carlos R. Modelagem dinâmica da COVID-19 com aplicação a algumas cidades brasileiras. **Revista Thema**, v. 18, p. 1-25, 2020.

GORTZ-BONALDO, Manuela. **Fatores críticos de sucesso na operação de serviço de mobilidade compartilhada**: Estudo de Caso do Serviço de Car-Sharing. 2021. 411 f. Tese (Doutorado em Tecnologia e Sociedade) – Programa de Pós-Graduação em Tecnologia e Sociedade, Universidade Tecnológica Federal do Paraná, Curitiba, 2021.

GOURINCHAS, Pierre O. Flattening the pandemic and recession curves. *In*: BALDWIN, Richard; WEDER DI MAURO, Beatrice. (ed.). **Mitigating the COVID-19 economic crisis: act fast and do whatever it takes**. London: CEPR Press, 2020, p. 31-40. ISBN: 978-1-912179-29-9.

HAN, Shasha *et al.* Time-varying optimization of COVID-19 vaccine prioritization in the context of limited vaccination capacity. **Nature Communications**, v. 12, n. 4673, p. 1-10, 2021.

HAUG, Nils *et al.* Ranking the effectiveness of worldwide COVID-19 government interventions. **Nature Human Behaviour**, v. 4, n. 12, p. 1303-1312, 2020.

HORTON, Richard. Offline: COVID-19 is not a pandemic. **The Lancet**, v. 396, n. 10255, p. 874, 2020.

HOSSEINI-MOTLAGH, Seyyed-Mahdi; SAMANI, Mohammad R. G.; HOMAEI, Shamim. Design of control strategies to help prevent the spread of COVID-19 pandemic. **European Journal of Operational Research**, v. 304, n. 1, p. 219-238, 2023.

HSIANG, Solomon *et al.* The effect of large-scale anti-contagion policies on the COVID-19 pandemic. **Nature**, v. 584, n. 7820, p. 262-267, 2020.

HULÍKOVÁ TESÁRKOVÁ, Klára; DZÚROVÁ, Dagmar. COVID-19: years of life lost (YLL) and saved (YLS) as an expression of the role of vaccination. **Scientific Reports**, v. 12, n. 1, p. 18129, 2022.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Projeção da População. *In*: Sistema IBGE de Recuperação Automática - SIDRA. **Esperança de vida ao nascer e taxa de mortalidade infantil, por sexo**. 2018. Disponível em: <https://sidra.ibge.gov.br/tabela/7362#/n1/all/n3/all/v/2503/p/all/c2/6794/c1933/49035/d/v2503%2020/v,p+c2,t+c1933/resultado>. Acesso em: 26 jul. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Projeção da população das Unidades da Federação por sexo e grupos de idade: 2000-2030**. 2020. Disponível em: <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/leiintbr.def>. Acesso em: 26 jul. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Tábuas completas de mortalidade em ano de pandemia de COVID-19**: Nota técnica n. 01/2021. Rio de Janeiro: IBGE, 2021a. 9 p. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101889>. Acesso em: 26 jul. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Sistema de contas regionais**: Brasil 2019. Rio de Janeiro: IBGE, 2021b. 12 p. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101873>. Acesso em: 26 jul. 2023.

INTERNATIONAL MONETARY FUND. **World Economic Outlook: Recovery during a pandemic - Health concerns, supply disruptions, price pressures.** Washington, DC: International Monetary Fund, out. 2021. 152 p. Disponível em: <https://www.imf.org/en/Publications/WEO/Issues/2021/10/12/world-economic-outlook-october-2021>. Acesso em: 26 jul. 2023.

JOHNS HOPKINS UNIVERSITY (Estados Unidos da América). **COVID-19 dashboard.** 2023. Disponível em: <https://coronavirus.jhu.edu/map.html>. Acesso em: 26 jul. 2023.

JORDAN, Elizabeth *et al.* Optimization in the context of COVID-19 prediction and control: a literature review. **IEEE Access**, v. 9, p. 130072-130093, 2021.

KALETA, Mariusz *et al.* Long-term spatial and population-structured planning of non-pharmaceutical interventions to epidemic outbreaks. **Computers & Operations Research**, v. 146, p. 105919, 2022.

KANTOR, Bella N.; KANTOR, Jonathan. Non-pharmaceutical interventions for pandemic COVID-19: a cross-sectional investigation of US general public beliefs, attitudes, and actions. **Frontiers in Medicine**, v. 7, p. 384, 2020.

KOCHAŃCZYK, Marek; LIPNIACKI, Tomasz. Pareto-based evaluation of national responses to COVID-19 pandemic shows that saving lives and protecting economy are non-trade-off objectives. **Scientific Reports**, v. 11, n. 2425, p. 1-9, 2021.

KUCHARSKI, Adam J., *et al.* Effectiveness of isolation, testing, contact tracing, and physical distancing on reducing transmission of SARS-CoV-2 in different settings: a mathematical modelling study. **The Lancet Infectious Diseases**, v. 20, n. 10, p. 1151-1160, 2020.

LACERDA, Rogério T. de O.; ENSSLIN, Leonardo; ENSSLIN, Sandra R. Uma análise bibliométrica da literatura sobre estratégia e avaliação de desempenho. **Gestão & Produção**, São Carlos, v. 19, n. 1, p. 59-78, 2012.

LAI, Shengjie *et al.* Effect of non-pharmaceutical interventions to contain COVID-19 in China. **Nature**, v. 585, n. 7825, p. 410-413, 2020.

LAYARD, Richard *et al.* **When to release the lockdown?** A wellbeing framework for analysing costs and benefits. Bonn, Germany: IZA – Institute of Labor Economics, 2020, 19 p. (IZA Discussion Paper No. 13186). ISSN 2365-9793. DOI: 10.2139/ssrn.3590884. Disponível em: <https://ssrn.com/abstract=3590884>. Acesso em: 26 jul. 2023.

LI, Xiaoming. A two-level policy for controlling an epidemic and its dynamics. **Omega**, v. 115, p. 102753, 2023.

LIBOTTE, Gustavo B. *et al.* Determination of an optimal control strategy for vaccine administration in COVID-19 pandemic treatment. **Computer Methods and Programs in Biomedicine**, v. 196, p. 105664, 2020.

- LIU, Ming *et al.* Integrated planning for public health emergencies: A modified model for controlling H1N1 pandemic. **Journal of the Operational Research Society**, v. 71, n. 5, p. 748-761, 2020.
- LIU, Yang *et al.* The impact of non-pharmaceutical interventions on SARS-CoV-2 transmission across 130 countries and territories. **BMC Medicine**, v. 19, n. 1, p. 1-12, 2021.
- LIU, Yan *et al.* What matters: non-pharmaceutical interventions for COVID-19 in Europe. **Antimicrobial Resistance & Infection Control**, v. 11, n. 3, p. 1-9, 2022.
- LUO, Li; WAN, Xinying; WANG, Qingyi. A multi-period location–allocation model for integrated management of emergency medical supplies and infected patients during epidemics. **Computers & Industrial Engineering**, v. 173, p. 108640, 2022.
- MASCARELLO, Keila C. *et al.* Potential years of life lost by COVID-19 in the state of Espírito Santo and proportional mortality by age. **Jornal Brasileiro de Pneumologia**, v. 48, n. 1, p. e20210489, 2022.
- MATHIEU, Edouard *et al.* Coronavirus pandemic (COVID-19). **Our world in data**, 2020. Disponível em: <https://ourworldindata.org/covid-stringency-index>. Acesso em: 26 jul. 2023.
- MATRAJT, Laura *et al.* Optimizing vaccine allocation for COVID-19 vaccines shows the potential role of single-dose vaccination. **Nature Communications**, v. 12, n. 3449, p. 1-18, 2021a.
- MATRAJT, Laura *et al.* Vaccine optimization for COVID-19: who to vaccinate first?. **Science Advances**, v. 7, n. 6, p. eabf1374, 2021b.
- MIKKULAINEN, Risto *et al.* From prediction to prescription: evolutionary optimization of nonpharmaceutical interventions in the COVID-19 pandemic. **IEEE Transactions on Evolutionary Computation**, v. 25, n. 2, p. 386-401, 2021.
- MITRA, Amal K. *et al.* Potential years of life lost due to COVID-19 in the United States, Italy, and Germany: an old formula with newer ideas. **International Journal of Environmental Research and Public Health**, v. 17, n. 12, p. 4392, 2020.
- MORATO, Marcelo M. *et al.* A parametrized nonlinear predictive control strategy for relaxing COVID-19 social distancing measures in Brazil. **ISA Transactions**, v. 124, p. 197-214, 2022.
- MORRIS, Dylan H. *et al.* Optimal, near-optimal, and robust epidemic control. **Communications Physics**, v. 4, n. 78, p. 1-8, 2021.
- NICOLA, Maria *et al.* The socio-economic implications of the coronavirus pandemic (COVID-19): a review. **International Journal of Surgery**, v. 78, p. 185-193, 2020.

NONATO, Luis G. *et al.* Robot Dance: A mathematical optimization platform for intervention against COVID-19 in a complex network. **EURO Journal on Computational Optimization**, v. 10, p. 100025, 2022.

NORONHA, Kenya V. M. S. *et al.* Pandemia por COVID-19 no Brasil: análise da demanda e da oferta de leitos hospitalares e equipamentos de ventilação assistida segundo diferentes cenários. **Cadernos de Saúde Pública**, v. 36, n. 6, p. e00115320, 2020.

NORRIS, Gregory A. Social impacts in product life cycles-towards life cycle attribute assessment. **The International Journal of Life Cycle Assessment**, v. 11, n. 1, p. 97-104, 2006.

OH, Djin-Ye *et al.* Trends in respiratory virus circulation following COVID-19-targeted non pharmaceutical interventions in Germany, January-September 2020: analysis of national surveillance data. **The Lancet Regional Health-Europe**, v. 6, p. 100112, 2021.

OH, In-Hwan *et al.* Years of life lost attributable to COVID-19 in high-incidence countries. **Journal of Korean Medical Science**, v. 35, n. 32, e300, 2020.

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE (OPAS). **Exercício de modelagem para COVID-19**: guia técnico - metodologia e parâmetros. Brasília, DF: OPAS, 2020. 13 p. Disponível em: <https://iris.paho.org/handle/10665.2/52236>. Acesso em: 26 jul. 2023.

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE (OPAS). **OMS declara fim da Emergência de Saúde Pública de Importância Internacional referente à COVID-19**: 5 maio 2023. 2023. Disponível em: <https://www.paho.org/pt/noticias/5-5-2023-oms-declara-fim-da-emergencia-saude-publica-importancia-internacional-referente>. Acesso em: 26 jul. 2023.

PAGE, Matthew J. *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, 2021.

PARÉ, Philip E.; BECK, Carolyn L.; BAŞAR, Tamer. Modeling, estimation, and analysis of epidemics over networks: An overview. **Annual Reviews in Control**, v. 50, p. 345-360, 2020.

PIFARRÉ I AROLAS, Héctor *et al.* Years of life lost to COVID-19 in 81 countries. **Scientific Reports**, v. 11, n. 1, p. 1-6, 2021.

PIRET, Jocelyne; BOIVIN, Guy. Pandemics throughout history. **Frontiers in Microbiology**, v. 11, p. 631736, 2021.

PORSSE, Alexandre A. *et al.* The economic impacts of COVID-19 in Brazil based on an interregional CGE approach. **Regional Science Policy & Practice**, v. 12, n. 6, p. 1105-1121, 2020.

PRADO, Marcelo F. do *et al.* Análise da subnotificação de COVID-19 no Brasil. **Revista Brasileira de Terapia Intensiva**, v. 32, n. 2, p. 224-228, 2020.

PREM, Kiesha; COOK, Alex R.; JIT, Mark. Projecting social contact matrices in 152 countries using contact surveys and demographic data. **PLoS Computational Biology**, v. 13, n. 9, p. e1005697, 2017.

PRESTON, Samuel H. The changing relation between mortality and level of economic development. **Population Studies**, v. 29, n. 2, p. 231-248, 1975.

QUAST, Troy *et al.* Years of life lost associated with COVID-19 deaths in the USA during the first 2 years of the pandemic. **Journal of Public Health**, v. 44, n. 3, p. e353-e358, 2022.

REDLIN, Margarete. Differences in NPI strategies against COVID-19. **Journal of Regulatory Economics**, v. 62, n. 1, p. 1-23, 2022.

RUIZ, Alice. **Dois em um**. São Paulo: Iluminuras, 2008. 208 p.

SALJE, Henrik *et al.* Estimating the burden of SARS-CoV-2 in France. **Science**, v. 369, n. 6500, p. 208-211, 2020.

SCARABAGGIO, Paolo *et al.* Nonpharmaceutical stochastic optimal control strategies to mitigate the COVID-19 spread. **IEEE Transactions on Automation Science and Engineering**, v. 19, n. 2, p. 560-575, 2022.

SCHEFFER, M. *et al.*, **Demografia médica no Brasil 2020**. São Paulo, SP: FMUSP, CFM, 2020. 312 p. ISBN: 978-65-00-12370-8.

SCHWARCZ, Lilia M. **Quando acaba o século XX**. São Paulo: Companhia das letras, 2020. 27 p.

SHARMA, Mrinank *et al.* Understanding the effectiveness of government interventions against the resurgence of COVID-19 in Europe. **Nature Communications**, v. 12, n. 1, p. 1-13, 2021.

SHIM, Eunha. Optimal allocation of the limited COVID-19 vaccine supply in South Korea. **Journal of Clinical Medicine**, v. 10, n. 4, p. 591, 2021.

SINGH, Rajesh; ADHIKARI, Ronojoy. Age-structured impact of social distancing on the COVID-19 epidemic in India. **ArXiv Preprint**, 2020. DOI: 10.48550/arXiv.2003.12055.

SOLTANISEHAT, Leili; GONZÁLEZ, Andrés D.; BARKER, Kash. Modeling social, economic, and health perspectives for optimal pandemic policy decision-making. **Socio-Economic Planning Sciences**, p. 101472, 2022.

TATAPUDI, Hanisha *et al.* Factor selection for influenza epidemic mitigation using bi-objective optimization. *In*: IISE ANNUAL CONFERENCE & EXPO, 2019, Orlando. **Proceedings [...]**. Orlando: IISE, 2019. p. 1361-1366.

UGARTE, Maider P. *et al.*, 2022. Premature mortality attributable to COVID-19: potential years of life lost in 17 countries around the world, January–August 2020. **BMC Public Health**, v. 22, n. 54, p. 1-13, 2022.

ULLRICH, Alexander *et al.* Impact of the COVID-19 pandemic and associated non-pharmaceutical interventions on other notifiable infectious diseases in Germany: an analysis of national surveillance data during week 1–2016–week 32–2020. **The Lancet Regional Health-Europe**, v. 6, p. 100103, 2021.

UNITED STATES AGENCY FOR INTERNATIONAL DEVELOPMENT (USAID). Tool 4: non-pharmaceutical interventions (NPIs): actions to limit the spread of the pandemic in your municipality. *In*: USAID. **Leadership during a pandemic**: what your municipality can do. [S. l.]: USAID, 2010. Disponível em: <https://www.hsdl.org/?abstract&did=750946>. Acesso em: 26 jul. 2023.

WANG, Haidong *et al.* Estimating excess mortality due to the COVID-19 pandemic: a systematic analysis of COVID-19-related mortality, 2020–21. **The Lancet**, v. 399, n. 10334, p. 1513-1536, 2022.

WOHLIN, Claes. Guidelines for snowballing in systematic literature studies and a replication in software engineering. *In*: 18th International Conference On Evaluation And Assessment In Software Engineering – Ease '14, 2014, London. **Proceedings [...]**. London: ACM Press, 2014. p.1-10.

WORLD HEALTH ORGANIZATION (WHO). **14.9 million excess deaths associated with the COVID-19 pandemic in 2020 and 2021**: 5 may 2022. 2022. Disponível em: <https://www.who.int/news/item/05-05-2022-14.9-million-excess-deaths-were-associated-with-the-covid-19-pandemic-in-2020-and-2021>. Acesso em: 26 jul. 2023.

WORLD HEALTH ORGANIZATION. **Ebola virus disease**. 2021. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/ebola-virus-disease>. Acesso em: 26 jul. 2023.

WORLD HEALTH ORGANIZATION. **Origin of SARS-CoV-2**: 26 march 2020. 2020a. Disponível em: <https://apps.who.int/iris/handle/10665/332197>. Acesso em: 26 jul. 2023.

WORLD HEALTH ORGANIZATION. **WHO Director-General's opening remarks at the media briefing on COVID-19**: 11 march 2020. 2020b. Disponível em: <https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>. Acesso em: 26 jul. 2023.

WU, Susie R. *et al.* Causality in social life cycle impact assessment (SLCIA). **The International Journal of Life Cycle Assessment**, v. 20, p. 1312-1323, 2015.

XU, Zhe; WU, Bo; TOPCU, Ufuk. Control strategies for COVID-19 epidemic with vaccination, shield immunity and quarantine: A metric temporal logic approach. **PLoS One**, v. 16, n. 3, p. e0247660, 2021.

YAESOUBI, Reza *et al.* Adaptive policies to balance health benefits and economic costs of physical distancing interventions during the COVID-19 pandemic. **Medical Decision Making**, v. 41, n. 4, p. 386-392, 2021.

YANG, Liu *et al.* Computational decision-support tools for urban design to improve resilience against COVID-19 and other infectious diseases: a systematic review. **Progress in Planning**, v. 168, p. 100657, 2023.

YIN, Xuecheng; BÜYÜKTAHTAKIN, İ. Esra; PATEL, Bhumi P. Covid-19: Data-driven optimal allocation of ventilator supply under uncertainty and risk. **European Journal of Operational Research**, v. 304, n. 1, p. 255-275, 2023.

ZARIC, Gregory S.; BRANDEAU, Margaret L. Resource allocation for epidemic control over short time horizons. **Mathematical Biosciences**, v. 171, n. 1, p. 33-58, 2001.

APÊNDICE A - Lista de verificação da Declaração PRISMA

Seção e tópico	Item	Item da lista de verificação
TÍTULO		
Título	1	Revisão sistemática: Minimização de Anos de Vida Perdidos em eventos epidêmicos considerando aspectos econômicos
RESUMO		
Resumo	2	A pandemia de COVID-19 ocasionou enormes perdas humanas e econômicas. Com a rápida disseminação e poucas informações no início da doença, governos em todo o mundo adotaram diversas intervenções não farmacêuticas para tentar mitigar ou suprimir as infecções. De modo a mensurar as perdas humanas e econômicas ocasionadas pela pandemia sob uma visão de impactos na saúde humana, utilizou-se o indicador de Anos de Vida Perdidos. Este estudo, portanto, teve como objetivo desenvolver um modelo matemático para minimizar os Anos de Vida Perdidos em situações de eventos epidêmicos, que considere a adoção de intervenções não farmacêuticas e os seus efeitos na economia. Seguindo as diretrizes da declaração PRISMA, foi conduzida uma revisão sistemática da literatura para encontrar modelos que pudessem servir como base para o desenvolvimento do modelo matemático proposto neste trabalho. O modelo proposto determina a alocação ideal de intervenções não farmacêuticas e considera as capacidades de recursos de saúde para minimizar os Anos de Vida Perdidos de uma população, decorrentes tanto das perdas humanas quanto das perdas econômicas causadas pela COVID-19. O modelo desenvolvido foi formulado como uma Programação Não Linear Inteira Mista, o qual foi transformado em um modelo de Programação Linear Inteira Mista por meio da linearização dos termos quadráticos. Aplicou-se o modelo utilizando dados reais da pandemia de COVID-19 para as 27 unidades da federação do Brasil, considerando três cenários distintos. Os resultados apontam para a predominância de Anos de Vida Perdidos provenientes das perdas econômicas. Os resultados destacam a utilidade do modelo ao fornecer orientações aos tomadores de decisão em relação a um portfólio de intervenções não farmacêuticas, levando em consideração o impacto dessas decisões na saúde e na economia, a fim de minimizar os impactos potenciais na saúde humana. O modelo e as análises também podem ser estendidos para o gerenciamento de eventuais epidemias futuras.
INTRODUÇÃO		
Justificativa	3	A revisão sistemática foi conduzida com o propósito de identificar na literatura modelos existentes que pudessem servir como base para a formulação do modelo proposto neste estudo.
Objetivos	4	<p>Pergunta de pesquisa: considerando que as perdas na saúde humana podem ocorrer tanto pela doença quanto pelos seus impactos na economia, como minimizar os Anos de Vida Perdidos por meio da adoção de INF?</p> <p>Objetivo geral: Desenvolver um modelo matemático para minimizar os Anos de Vida Perdidos em situações de eventos epidêmicos, que considere a adoção de INF e os seus efeitos na economia, e testá-lo utilizando dados da literatura.</p> <p>Objetivos específicos:</p> <p>a) Identificar na literatura modelos correlatos ao contexto de trabalho que auxiliem na construção do próprio modelo a ser proposto;</p>

Seção e tópico	Item	Item da lista de verificação
		b) Desenvolver o modelo de otimização conectando os objetivos social e econômico de modo a minimizar os impactos potenciais na saúde humana; c) Aplicar o modelo construído para as 27 unidades da federação do Brasil considerando diferentes cenários; d) Realizar uma análise de sensibilidade em parâmetros do modelo para verificar possíveis mudanças significativas nos resultados.
MÉTODOS		
Critérios de elegibilidade	5	Critérios para a varredura nas bases e seleção dos artigos: <ul style="list-style-type: none"> • Recorte temporal: 2018-2023 (últimos 5 anos) • Idiomas considerados: Inglês • Tipos de publicações: artigos de periódicos, capítulos de livro, livros, artigos de eventos científicos.
Fontes de informação	6	Bases científicas selecionadas: 3 bases internacionais: <i>Science Direct</i> , <i>Scopus</i> , <i>Web of Science</i> Recorte temporal: 2018-2023. Última pesquisa realizada em: 09/01/2023.
Estratégia de busca	7	Estratégia de busca utilizada nas 3 bases científicas selecionadas, passível de ser replicada: <i>Advanced search: ("integer programming" OR "mixed integer linear programming") AND ("infectious disease" OR epidemic OR pandemic OR covid) AND ("non-pharmaceutical interventions" OR "epidemic control")</i> . Years: 2018-2023. A busca foi realizada ao longo de todo o texto, não sendo limitada ao título, resumo e palavras-chave.
Processo de seleção	8	1º filtro - Triagem - Leitura dinâmica dos elementos: Título, resumo e palavras-chave Eliminação de referências sem alinhamento com o objetivo da pesquisa, e que apresentam como foco: <ol style="list-style-type: none"> a) Cadeia de suprimentos; b) Vacinação; c) Alocação e distribuição de recursos de saúde; d) Gestão de resíduos; e) Logística; f) Palavras-chave utilizadas na busca apareceram ao longo do texto, porém não eram o foco da publicação. 2º filtro - Leitura completa dos artigos Eliminação de referências sem alinhamento com o objetivo da pesquisa, que não apresentavam modelos matemáticos de otimização e tratavam de: <ol style="list-style-type: none"> a) Desenvolvimento de algoritmo; b) Análise de custo-benefício (não possui otimização);

Seção e tópico	Item	Item da lista de verificação
		c) Editorial de revista científica focada no papel da pesquisa operacional em epidemias futuras; d) Revisão sistemática da literatura com foco no design urbano para melhorar a resiliência contra doenças infecciosas.
Processo de coleta de dados	9	A busca foi realizada pela pesquisadora nas 3 bases científicas, utilizando a estratégia de busca mencionada no item 7, com importação e armazenamento dos dados para o <i>software</i> Zotero 6.0.19 a cada busca.
Lista dos dados	10a	Importação das 75 referências iniciais coletadas para o <i>software</i> Zotero, para armazenamento e posterior seleção.
	10b	Não é aplicável.
Avaliação do risco de viés dos estudos	11	Não é aplicável.
Medidas de efeito	12	Não é aplicável.
Métodos de síntese	13a	Os estudos incluídos após a leitura completa foram avaliados com base em aspectos de interesse como: foco do estudo, a doença, o modelo compartimental epidêmico, INF testadas, formulação do problema (função objetivo, restrições, variáveis de decisão), técnica de otimização, softwares utilizados, escala temporal e geográfica do estudo de caso e se faz análise de sensibilidade.
	13b	Não é aplicável.
	13c	O Quadro 2, apresentado na seção 2.4, foi confeccionado para tabular os resultados e sintetizar os principais aspectos de interesse avaliados para cada um dos estudos incluídos.
	13d	Não é aplicável.
	13e	Não é aplicável.
	13f	Não é aplicável.
Avaliação de vieses de publicação	14	Não é aplicável.
Avaliação da certeza	15	Não é aplicável.
RESULTADOS		
Seleção de estudos	16a	Os resultados do processo de busca e seleção, desde o número de registros identificados na busca até o número de estudos incluídos na revisão, podem ser vistos na Figura 3, apresentada na seção 2.3 desta dissertação.
	16b	O estudo de Xiaoming (2023) trata de política de dois níveis para controlar a COVID-19 e apresenta um modelo matemático,

Seção e tópico	Item	Item da lista de verificação
		porém ao realizar a leitura completa do artigo, percebeu-se que o autor fez apenas uma análise de custo-benefício (não utilizando otimização, de fato). Por esse motivo o estudo não foi incluído no <i>corpus</i> final.
Características do estudo	17	Artigos que contêm relação com as palavras-chave selecionadas e que apresentam modelos matemáticos descritos de maneira clara (função objetivo, restrições e técnica de otimização).
Risco de viés nos estudos	18	Não aplicável.
Resultados de estudos individuais	19	Não aplicável.
Resultados das sínteses	20a	13 referências selecionadas ao final (<i>corpus</i> dinâmico).
	20b	Não é aplicável.
	20c	Não é aplicável.
	20d	Não é aplicável.
Viés de publicação	21	Não é aplicável.
Certeza da evidência	22	Não é aplicável.
DISCUSSÃO		
Discussão	23a	Referências selecionadas para construir o referencial teórico desta dissertação e apoiar na formulação do modelo matemático.
	23b	Não é aplicável.
	23c	Como uma possível limitação desta revisão sistemática, pode-se citar o recorte temporal utilizado (últimos cinco anos), que pode não incluir algum estudo importante. De modo a superar tal limitação, buscou-se utilizar o método <i>snowball</i> , para garantir que estudos importantes ou clássicos fossem incluídos.
	23d	Não é aplicável.
OUTRAS INFORMAÇÕES		
Registro e protocolo	24a	A revisão não foi registrada.
	24b	Não consta protocolo.
	24c	Não é aplicável.
Apoio	25	Pesquisa desenvolvida pela pesquisadora com financiamento da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).
Interesses	26	Não há conflito de interesses.

Seção e tópico	Item	Item da lista de verificação
conflitantes		
Disponibilidade de dados, código e outros materiais	27	Uma tabela completa contendo as duas etapas de filtragem e as características extraídas dos estudos incluídos na revisão poderá ser disponibilizada mediante solicitação.

Fonte: Autoria própria, adaptado de Page et al. (2021)

APÊNDICE B - Modelo matemático linearizado

Função objetivo:

$$\begin{aligned}
 \text{Minimize } z = & \sum_{k=1}^{|K|} \sum_{t=1}^{|T|} ((1 - \lambda_2)\gamma_2 Q_{2kt} + (1 - \lambda_3)\gamma_3 Q_{3kt} + s_{2kt}) AVP_{\text{médio } k} \\
 & + \sum_{k=1}^{|K|} \sum_{i \in N} \sum_{t=1}^{|T|} \left(-b p_k^{c+1} (PIB_{0k}^{-c} - (PIB_{0k} + \Delta PIB_{ki})^{-c}) \right) x_{kit}
 \end{aligned} \tag{1}$$

Sujeito a:

$$\sum_{i \in N} x_{kit} = 1 \quad \forall t \in T, \quad \forall k \in K \tag{54}$$

$$\sum_{i \in N} x_{kit-1} w_i \geq \sum_{i \in N} x_{kit} w_i \quad \forall t \in \{2, \dots, |T|\}, \quad \forall k \in K \tag{55}$$

$$s_{1kt} = \frac{Y_{1kt}}{m} - (1 - \eta_{1k}) Y_{0kt} \quad \forall t \in T, \quad \forall k \in K \tag{56}$$

$$s_{2kt} = \theta Y_{2kt} - (1 - \eta_{2k}) l_{2k} z_{2kt} \quad \forall t \in T, \quad \forall k \in K \tag{57}$$

$$s_{3kt} = (1 - \theta) Y_{3kt} - (1 - \eta_{3k}) l_{3k} z_{3kt} \quad \forall t \in T, \quad \forall k \in K \tag{58}$$

$$Q_{1kt} = (1 - \eta_{1k}) Y_{0kt} + \frac{C_{kt} - Y_{1kt}}{m} \quad \forall t \in T, \quad \forall k \in K \tag{59}$$

$$Q_{1kt} \leq (1 - \eta_{1k}) H_{kt} \quad \forall t \in T, \quad \forall k \in K \tag{60}$$

$$Q_{1kt} \leq \frac{C_{kt}}{m} \quad \forall t \in T, \quad \forall k \in K \tag{61}$$

$$Q_{2kt} = (1 - \eta_{2k}) l_{2k} z_{2kt} + \theta (C_{kt} - Y_{2kt}) \quad \forall t \in T, \quad \forall k \in K \tag{62}$$

$$Q_{2kt} \leq (1 - \eta_{2k}) l_{2k} \quad \forall t \in T, \quad \forall k \in K \tag{63}$$

$$Q_{2kt} \leq \theta C_{kt} \quad \forall t \in T, \quad \forall k \in K \tag{64}$$

$$Q_{3kt} = (1 - \eta_{3k})l_{3k}z_{3kt} + (1 - \theta)(C_{kt} - Y_{3kt}) \quad \forall t \in T, \quad \forall k \in K \quad (65)$$

$$Q_{3kt} \leq (1 - \eta_{3k})l_{3k} \quad \forall t \in T, \quad \forall k \in K \quad (66)$$

$$Q_{3kt} \leq (1 - \theta)C_{kt} \quad \forall t \in T, \quad \forall k \in K \quad (67)$$

$$Q_{0kt} = m(s_{1kt} - U_{1kt}) + U_{3kt} \quad \forall t \in T, \quad \forall k \in K \quad (68)$$

$$Q_{0kt} \geq ms_{1kt} \quad \forall t \in T, \quad \forall k \in K \quad (69)$$

$$Q_{0kt} \geq s_{3kt} \quad \forall t \in T, \quad \forall k \in K \quad (70)$$

$$I_{k\ t+1} = I_{kt} + \sum_{i \in N} \beta X_{kit} - \rho \varphi I_{kt} - (1 - \rho) \mu I_{kt} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (71)$$

$$C_{k\ t+1} = C_{kt} + \rho \varphi I_{kt} - \lambda_2 \gamma_2 Q_{2kt} - \lambda_3 \gamma_3 Q_{3kt} - (1 - \lambda_2) \gamma_2 Q_{2kt} - (1 - \lambda_3) \gamma_3 Q_{3kt} + \gamma_3 Q_{0kt} - s_{2kt} - \gamma_3 s_{3kt} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (72)$$

$$H_{k\ t+1} = H_{kt} - \beta(Q_{2kt} + Q_{3kt}) \quad \forall t \in \{1\}, \quad \forall k \in K \quad (73a)$$

$$H_{k\ t+1} = H_{kt} - \beta(Q_{2kt} + Q_{3kt}) + \beta(Q_{2k\ t-1} + Q_{3k\ t-1}) \left(\frac{1 - \rho + \rho \theta \lambda_2 \gamma_2 + \rho(1 - \theta) \lambda_3 \gamma_3}{\bar{\tau}} \right) \quad \forall t \in \{2, \dots, |T| - 1\}, \quad \forall k \in K \quad (73b)$$

$$S_{k\ t+1} = S_{kt} - \sum_{i \in N} \beta X_{kit} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (74)$$

$$R_{k\ t+1} = R_{kt} + \lambda_2 \gamma_2 Q_{2kt} + \lambda_3 \gamma_3 Q_{3kt} + (1 - \rho) \mu I_{kt} - \gamma_3 Q_{0kt} + \gamma_3 s_{3kt} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (75)$$

$$M_{k\ t+1} = M_{kt} + (1 - \lambda_2) \gamma_2 Q_{2kt} + (1 - \lambda_3) \gamma_3 Q_{3kt} + s_{2kt} \quad \forall t \in T \setminus \{|T|\}, \quad \forall k \in K \quad (76)$$

$$x_{kit} \in \{0,1\} \quad \forall t \in T, \quad \forall k \in K, \quad \forall i \in N \quad (77)$$

$$z_{0kt}, z_{rkt} \in \{0,1\} \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in Rec \quad (78)$$

$$I_{kt}, C_{kt}, H_{kt}, S_{kt}, R_{kt}, M_{kt} \geq 0 \quad \forall t \in T, \quad \forall k \in K \quad (79)$$

$$s_{rkt}, Q_{0kt}, Q_{rkt} \geq 0 \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in Rec \quad (80)$$

$$X_{kit}, Y_{0kt}, Y_{rkt} \geq 0 \quad \forall t \in T, \quad \forall k \in K, \quad \forall i \in N, \quad \forall r \in Rec \quad (81)$$

$$U_{rkt} \geq 0 \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in \{1,3\} \quad (82)$$

- **Linearização de $(1 - \alpha_i)(1 - \rho\epsilon)x_{kit}I_{kt} = X_{kit}$:**

$$X_{kit} \geq (1 - \alpha_i)(1 - \rho\epsilon)V_{kt}x_{kit} \quad \forall t \in T, \quad \forall k \in K, \quad i \in N \quad (83)$$

$$X_{kit} \leq I_{max}x_{kit} \quad \forall t \in T, \quad \forall k \in K, \quad i \in N \quad (84)$$

$$X_{kit} \geq (1 - \alpha_i)(1 - \rho\epsilon)I_{kt} - I_{max}(1 - x_{kit}) \quad \forall t \in T, \quad \forall k \in K, \quad i \in N \quad (85)$$

$$X_{kit} \geq (1 - \alpha_i)(1 - \rho\epsilon)(I_{kt} - V_{kt}(1 - x_{kit})) \quad \forall t \in T, \quad \forall k \in K, \quad i \in N \quad (86)$$

- **Linearização de $H_{kt}z_{1kt} = Y_{0kt}$:**

$$Y_{0kt} \geq 0 \quad \forall t \in T, \quad \forall k \in K \quad (87)$$

$$Y_{0kt} \leq H_{k1}z_{1kt} \quad \forall t \in T, \quad \forall k \in K \quad (88)$$

$$Y_{0kt} \geq H_{kt} - H_{k1}(1 - z_{1kt}) \quad \forall t \in T, \quad \forall k \in K \quad (89)$$

$$Y_{0kt} \leq H_{kt} \quad \forall t \in T, \quad \forall k \in K \quad (90)$$

- **Linearização de $C_{kt}z_{rkt} = Y_{rkt}$**

$$Y_{rkt} \geq 0 \quad \forall t \in T, \quad \forall k \in K, \quad r \in Rec \quad (91)$$

$$Y_{rkt} \leq \rho I_{max} z_{rkt} \quad \forall t \in T, \quad \forall k \in K, \quad r \in Rec \quad (92)$$

$$Y_{rkt} \geq C_{kt} - \rho I_{max}(1 - z_{rkt}) \quad \forall t \in T, \quad \forall k \in K, \quad r \in Rec \quad (93)$$

$$Y_{rkt} \leq C_{kt} \quad \forall t \in T, \quad \forall k \in K, \quad r \in Rec \quad (94)$$

• **Linearização de $s_{rkt} z_{0kt} = U_{rkt}$:**

$$U_{rkt} \geq 0 \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in \{1, 3\} \quad (95)$$

$$U_{rkt} \leq \rho I_{max} z_{0kt} \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in \{1, 3\} \quad (96)$$

$$U_{rkt} \geq s_{rkt} - \rho I_{max}(1 - z_{0kt}) \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in \{1, 3\} \quad (97)$$

$$U_{rkt} \leq s_{rkt} \quad \forall t \in T, \quad \forall k \in K, \quad \forall r \in \{1, 3\} \quad (98)$$

APÊNDICE C - Valores dos parâmetros do modelo por UF

Tabela 7 – Parâmetros do modelo por UF

k	UF k	Sigla	H_{k1}	l_{2k}	l_{3k}	η_{1k} (%)	η_{2k} (%)	η_{3k} (%)	S_{kt}	I_{kt}	C_{kt}	R_{kt}	M_{kt}	V_{k1}
1	Acre	AC	902	156	998	31,56	58,97	58,97	866.536	270,0	5,0	0	0	270,0
2	Alagoas	AL	3.697	739	4.111	37,44	62,65	62,65	3.419.535	151,2	2,8	0	0	151,2
3	Amapá	AP	801	134	774	33,42	67,91	67,91	842.870	43,2	0,8	0	0	43,2
4	Amazonas	AM	4.464	785	3.646	32,04	67,77	67,77	4.238.988	1.198,8	22,2	0	1	1.198,8
5	Bahia	BA	19.433	3.254	18.741	33,66	62,97	62,97	15.521.447	1.382,4	25,6	0	0	1.382,4
6	Ceará	CE	12.231	2.096	12.010	34,02	59,26	59,26	9.174.817	3.477,6	64,4	0	4	3.477,6
7	Distrito Federal	DF	12.669	2.056	4.772	42,96	86,14	86,14	3.220.188	2.808,0	52,0	0	0	2.808,0
8	Espírito Santo	ES	8.723	1.811	5.511	39,90	66,26	66,26	4.138.074	572,4	10,6	0	0	572,4
9	Goiás	GO	13.286	1.991	11.084	35,46	76,90	76,90	7.016.879	604,8	11,2	0	1	604,8
10	Maranhão	MA	6.045	1.213	9.414	30,60	67,60	67,60	7.121.002	151,2	2,8	0	0	151,2
11	Mato Grosso	MT	5.553	1.125	4.994	34,86	71,73	71,73	3.454.949	140,4	2,6	0	0	140,4
12	Mato Grosso do Sul	MS	5.379	734	3.599	36,90	73,30	73,30	2.800.363	334,8	6,2	0	0	334,8
13	Minas Gerais	MG	46.145	6.470	30.359	36,48	70,60	70,60	21.449.101	2.214,0	41,0	0	0	2.214,0
14	Pará	PA	7.102	1.821	9.651	31,20	59,64	59,64	8.628.714	183,6	3,4	0	0	183,6
15	Paraíba	PB	6.178	974	5.228	34,02	73,72	73,72	4.097.705	151,2	2,8	0	0	151,2
16	Paraná	PR	23.609	3.776	18.074	38,64	78,50	78,50	11.537.053	1.436,4	26,6	0	2	1.436,4
17	Pernambuco	PE	14.836	3.144	15.850	31,56	59,64	59,64	9.649.851	734,4	13,6	0	5	734,4
18	Piauí	PI	4.300	754	4.929	32,22	53,71	53,71	3.233.769	118,8	2,2	0	1	118,8
19	Rio de Janeiro	RJ	46.180	8.492	23.636	33,60	74,52	74,52	16.940.390	6.026,4	111,6	0	13	6.026,4
20	Rio Grande do Norte	RN	5.244	1.087	4.868	33,24	60,07	60,07	3.597.793	486,0	9,0	0	0	486,0
21	Rio Grande do Sul	RS	25.055	3.255	20.420	42,12	75,61	75,61	11.414.726	2.127,6	39,4	0	2	2.127,6
22	Rondônia	RO	2.673	513	3.064	30,24	69,01	69,01	1.857.926	64,8	1,2	0	0	64,8
23	Roraima	RR	841	91	1.205	33,12	61,54	61,54	546.759	129,6	2,4	0	0	129,6
24	Santa Catarina	SC	15.823	1.798	10.415	40,26	66,57	66,57	7.264.168	1.987,2	36,8	0	1	1.987,2
25	São Paulo	SP	117.259	17.658	59.849	38,10	70,93	70,93	46.049.378	15.184,8	281,2	0	84	15.184,8
26	Sergipe	SE	3.459	517	2.510	37,02	69,05	69,05	2.352.031	172,8	3,2	0	0	172,8
27	Tocantins	TO	2.723	342	2.063	29,22	81,29	81,29	1.599.217	97,2	1,8	0	0	97,2

Fonte: Autoria própria (2023).

Tabela 8 – Parâmetros do modelo por UF

<i>k</i>	Sigla	<i>AVP</i> _{médio <i>k</i>}	<i>p_k</i>	<i>PIB</i> _{0<i>k</i>}	ΔPIB_{ki} (R\$/semana)				
					<i>i</i> = 1	<i>i</i> = 2	<i>i</i> = 3	<i>i</i> = 4	<i>i</i> = 5
1	AC	13,74	866.811	15.630.000.000	-688.108	-2.523.063	-3.899.279	-8.027.928	-15.597.117
2	AL	12,73	3.419.689	58.964.000.000	-1.665.376	-6.106.379	-9.437.132	-19.429.388	-37.748.526
3	AP	14,51	842.914	17.497.000.000	-607.969	-2.229.221	-3.445.159	-7.092.975	-13.780.637
4	AM	12,54	4.240.210	108.181.000.000	-3.402.525	-12.475.925	-19.280.975	-39.696.125	-77.123.899
5	BA	12,32	15.522.855	293.241.000.000	-11.079.186	-40.623.681	-62.782.052	-129.257.166	-251.128.209
6	CE	10,89	9.178.363	163.575.000.000	-6.165.982	-22.608.600	-34.940.564	-71.936.455	-139.762.255
7	DF	12,01	3.223.048	273.614.000.000	-2.413.638	-8.850.005	-13.677.280	-28.159.106	-54.709.119
8	ES	11,60	4.138.657	137.346.000.000	-3.831.557	-14.049.043	-21.712.158	-44.701.501	-86.848.630
9	GO	11,87	7.017.496	208.672.000.000	-8.806.785	-32.291.543	-49.905.113	-102.745.820	-199.620.451
10	MA	11,35	7.121.156	97.340.000.000	-3.247.236	-11.906.532	-18.401.004	-37.884.420	-73.604.015
11	MT	14,00	3.455.092	142.122.000.000	-4.408.427	-16.164.231	-24.981.085	-51.431.645	-99.924.338
12	MS	11,66	2.800.704	106.943.000.000	-2.992.674	-10.973.138	-16.958.486	-34.914.530	-67.833.945
13	MG	10,47	21.451.356	651.873.000.000	-25.476.804	-93.414.949	-144.368.558	-297.229.385	-577.474.233
14	PA	12,40	8.628.901	178.377.000.000	-5.270.072	-19.323.597	-29.863.740	-61.484.171	-119.454.961
15	PB	12,00	4.097.859	67.986.000.000	-2.279.784	-8.359.209	-12.918.778	-26.597.484	-51.675.113
16	PR	11,33	11.538.518	466.377.000.000	-17.701.460	-64.905.355	-100.308.275	-206.517.038	-401.233.102
17	PE	11,64	9.650.604	197.853.000.000	-7.595.339	-27.849.578	-43.040.257	-88.612.293	-172.161.027
18	PI	11,30	3.233.891	52.781.000.000	-2.136.036	-7.832.133	-12.104.206	-24.920.424	-48.416.823
19	RJ	11,38	16.946.541	779.928.000.000	-13.236.852	-48.535.122	-75.008.825	-154.429.935	-300.035.302
20	RN	11,90	3.598.288	71.337.000.000	-2.392.154	-8.771.231	-13.555.539	-27.908.463	-54.222.156
21	RS	10,26	11.416.895	482.464.000.000	-19.567.053	-71.745.862	-110.879.969	-228.282.290	-443.519.877
22	RO	14,57	1.857.992	47.091.000.000	-2.240.583	-8.215.472	-12.696.639	-26.140.140	-50.786.557
23	RR	15,38	546.891	14.292.000.000	-246.280	-903.026	-1.395.586	-2.873.266	-5.582.345
24	SC	10,79	7.266.193	323.264.000.000	-13.054.399	-47.866.128	-73.974.926	-152.301.317	-295.899.702
25	SP	11,41	46.064.928	2.348.338.000.000	-77.932.678	-285.753.153	-441.618.509	-909.214.577	-1.766.474.036
26	SE	13,33	2.352.207	44.689.000.000	-1.010.325	-3.704.526	-5.725.177	-11.787.128	-22.900.706
27	TO	12,21	1.599.316	39.356.000.000	-1.183.231	-4.338.514	-6.704.976	-13.804.362	-26.819.903

Fonte: Autoria própria (2023).