LII Simpósio Brasileiro de Pesquisa Operacional
João Pessoa - PB, 3 a 5 de novembro de 2020

MODELO DE SIMULAÇÃO BASEADA EM AGENTES PARA AVALIAÇÃO DE INTERVENÇÕES NÃO FARMACOLÓGICAS FRENTE A SÍNDROMES RESPIRATÓRIAS AGUDAS GRAVES

Thiago Augusto de Oliveira Silva, Paganini Barcellos de Oliveira, Alexandre Xavier Martins, Felipo Bacani
Universidade Federal de Ouro Preto, Instituto de Ciências Exatas e Aplicadas,
Departamento de Engenharia de Produção, João Monlevade, Brasil
Rua 36, 115 - Loanda, João Monlevade - MG, 35931-008
thiago@ufop.edu.br, paganini@ufop.edu.br, xmartins@ufop.edu.br, fbacani@ufop.edu.br

RESUMO

A proposição de medidas e estratégias não farmacológicas para combate e suavização dos impactos provenientes de eventuais surtos epidemiológicos é uma demanda recorrente na sociedade. Em pelo menos cinco ocasiões, nos primeiros anos do Século XXI, a humanidade precisou lidar com epidemias de Síndromes Respiratórias Agudas Graves (SRAGs), o que impulsionou o desenvolvimento de metodologias eficazes e eficientes quanto à minimização da taxa de mortalidade causada pelo surto da doença. O presente trabalho propõe um modelo de simulação baseada em agentes para avaliar o impacto de ações não farmacológicas no controle da disseminação de uma doença, que provoca complicações de caráter respiratório em seres humanos. Como resultado, verificou-se que medidas como o isolamento horizontal combinado com determinados percentuais de testagem de contaminação da população pela doença, podem reduzir, significativamente, os índices de mortalidade em uma determinada região geográfica.

PALAVRAS CHAVE. Simulação baseada em agentes. Síndromes Respiratórias Agudas Graves. Soluções não farmacológicas.

SA – PO na Área de Saúde, SIM – Simulação

ABSTRACT

The development of non-pharmacological solutions and strategies for combating and mitigating the impacts arising from eventual epidemiological outbreaks is a recurring need in our society. On at least five occasions, in the early years of the XXI century, humanity had to deal with epidemics of Severe Acute Respiratory Syndromes (SARSs), which spurred the development of effective and efficient methodologies for minimizing the mortality rate caused by the disease outbreak. This paper proposes an agent-based simulation model to assess the impact of non-pharmacological actions in the dissemination control of a disease, which causes respiratory complications in humans. As a result, it was found that strategies such as horizontal isolation combined with a predetermined percentage of testing population contamination by the disease, can significantly reduce mortality rates in a given geographic region.

KEYWORDS. Agent-based simulation. Severe Acute Respiratory Syndrome. Non-pharmacological solutions.

SA – OR in the Health Area, SIM – Simulation

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

1. Introdução

Dentro do contexto vivenciado pela pandemia de COVID-19, é necessário lembrar que, nos últimos vinte anos, o mundo vivenciou outras quatro grandes epidemias de Síndromes Respiratórias Agudas Graves (SRAGs), sendo a Síndrome Respiratória Aguda Severa - SARS (2003), a H5N1 - Gripe aviária (2006), a H1N1 - Gripe suína (2009) e a Síndrome Respiratória do Oriente Médio - MERS (2012). De acordo com [Lana et al., 2020], há um esforço mundial no sentido de disponibilizar e tratar matemática e estatisticamente informações em tempo real para o monitoramento da difusão do novo Coronavírus.

O sucesso no enfrentamento destas epidemias passa por uma estruturação logística emergencial articulada entre a sociedade e o poder público. Cabe aos governos a implementação de medidas não farmacológicas para o controle da disseminação da doença que, por sua vez, necessitam de embasamento científico para a comprovação de sua eficácia.

Neste trabalho, pretende-se utilizar a Modelagem e Simulação Baseada em Agentes (ABMS) - ver, e.g., [Siegfried, 2014], [Heppenstall et al., 2012] e [Taylor, 2014] - que é uma ferramenta numérica utilizada para modelar sistemas complexos caracterizados pela presença de agentes autônomos que interagem entre si. A partir da construção destes modelos é possível estimar o impacto de intervenções no sistema estudado e análise do comportamento dos agentes em diversos cenários. Por se tratar de uma ferramenta de grande flexibilidade, é possível aplicar em diferentes problemas em várias áreas de atuação, tais como mercado financeiro, logística e cadeia de suprimentos, sistemas biológicos e disseminação de epidemias. Especificamente, pretende-se utilizar a metodologia para modelar os efeitos da evolução da pandemia de Covid-19 em uma determinada região geográfica, com uma densidade populacional pré-definida.

Outros trabalhos utilizaram a metodologia para análise da dispersão de epidemias (ver, e.g., [Arifin et al., 2016]) e recentemente para o estudo da pandemia de Covid-19 [Ivanov, 2020] e [Ferguson et al., 2020], porém, os modelos possuem diferentes níveis de detalhamento e avaliam diferentes medidas de combate, em relação às apresentadas no presente artigo.

Este trabalho está organizado conforme descrito a seguir. A Seção 1 apresenta uma breve introdução e a contextualização do problema e abordagem proposta. A Seção 2 introduz o modelo de simulação e suas particularidade, a caracterização dos agentes, bem como as ações e políticas o enfrentamento modeladas. Já na Seção 3 são apresentados os resultados computacionais provenientes de diferentes cenários de simulação, avaliados por meio de análises estatísticas. Por fim, um compilado dos desdobramentos dos resultados computacionais são sumarizados na Seção 4, incluindo as conclusões obtidas e sugestão para trabalhos futuros.

2. Construção do Modelo

O modelo de difusão de vírus causadores de doença tipo SRAG se baseia na interação de pessoas e entre pessoas e locais em uma comunidade. A doença é caracterizada pelos parâmetros: taxa de infecção, percentual de casos graves, chance de recuperação, percentual de pacientes que apresentam sintomas, duração da virose e tempo de permanência do vírus no ambiente. Os doentes com casos graves, que não receberem atendimento especial, vão a óbito. Caso recebam atendimento, podem ou não se recuperar. O sistema simulado é caracterizado pelo número inicial de casos e percentual da população no grupo de risco.

O mundo simulado foi construído considerando uma área de $10km^2$ representados por 10.000 locais de $100m^2$. O número de habitantes é definido com base no parâmetro "densidade demográfica" informada. O mundo possui residências cuja quantidade é definida pelo parâmetro "residentes por domicílio". Cada pessoa possui um local de residência que, em caso de isolamento social, só pode ser acessado por residentes. A capacidade de atendimento de casos graves do sistema local é um dado de entrada.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

2.1. Definição de locais

Os locais podem ser pontos de circulação ou residências, e podem ser infectados caso um agente tipo pessoa, infectada, transite por lá. O local permanece infectado por um tempo de sobrevivência do vírus no ambiente, parâmetro do modelo.

2.2. Definição dos agentes

As pessoas são entidades autônomas de decisão, modeladas para acatar as medidas de segurança sanitárias vigentes. Durante o dia o agente se locomove aleatoriamente pelos pontos do mapa e pode ser infectado quando tem contato com algum doente ou com um local que possua o vírus. Uma vez infectado, o agente pode infectar outros agentes e locais. A Figura 2.1 apresenta o diagrama simplificado de estados de um agente. Os estados de uma agente são determinados pelo valor de seus atributos. Na Figura 2.1, os estados (círculos cinza) foram divididos em quatro grupos e onze estados, descritos na Tabela 1.

Tabela 1: Caracterização dos grupos e agentes do modelo de simulação.

Símbolo	Descrição
Grupos	
S	Saudáveis, quando o agente não foi infectado.
I	Infectados, quando o agente está doente.
R	Recuperados, após o agente se recuperar da doença.
M	Mortos, em caso de falecimento.
Estados dos agentes	
Sc	Saudável e circulante.
Si	Saudável e em isolamento social.
Ic	Infectado e circulante.
Ii	Infectado e em isolamento social.
Is	Infectado, apresentando sintomas e em isolamento social.
Ica	Infectado assintomático e circulante.
Iia	Infectado assintomático e em isolamento social.
Iii	Infectado assintomático identificado por teste em isolamento social.
G	Infectado em estado grave.
Ga	Infectado em estado grave recebendo tratamento adequado.
R	Recuperado.

A cada dia, o agente poderá ou não circular no ambiente, a depender da política de isolamento vigente, de sua necessidade, e de seus atributos "grupo de risco" e "trabalhador essencial". Para um agente saudável, as transições entre os estados circulante ou em isolamento são representados na Figura 2.1 pelos caminhos (p_1 e p_2). Todo agente saudável está suscetível à infecção, mesmo em isolamento, que ocorre quando há contado com infectados ou locais onde infectados estiveram (p_3 e p_4). Uma vez infectado, um agente pode apresentar sintomas ($d_1 \rightarrow p_5$, $d_2 \rightarrow p_7$) e, neste caso, a doença é identificada e o paciente colocado em isolamento, onde aguardará a recuperação, caso a doença não se agrave ($d_3 \rightarrow p_{10}$). Pacientes sintomáticos podem evoluir o quadro para um caso grave ($d_3 \rightarrow p_9$) e vir a óbito caso não recebam tratamento adequado ($d_4 \rightarrow p_{13}$). Pacientes em estado crítico que receberem tratamento adequado (Ga), podem se recuperar ($d_5 \rightarrow p_{14}$) ou vir a óbito ($d_5 \rightarrow p_{15}$). Agentes infectados assintomáticos (Ica e Iia) podem alternar entre isolamento e circulação ($d_6 \rightarrow p_{18}$ e $d_7 \rightarrow p_{17}$) como os agentes saudáveis até se recuperar ($d_6 \rightarrow p_{11}$ e

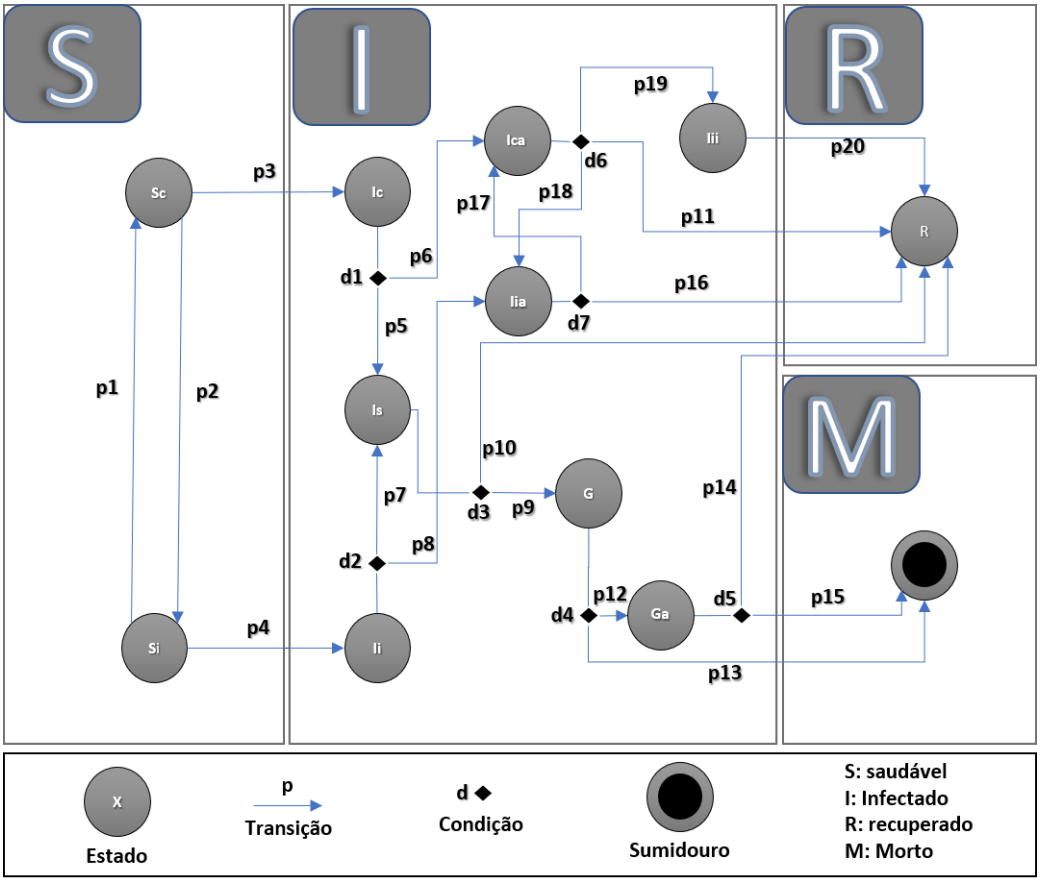


Figura 2.1: Diagrama de estados de um agente no sistema.

$d_7 \rightarrow p_{16}$). Infectados circulantes assintomáticos podem ter a doença identificada por testagem ($d_6 \rightarrow p_{19}$) e, neste caso, são postos em isolamento (Iii) até se recuperar (p_{20}).

2.3. Ações e Políticas

De acordo com [Valdez et al., 2013] a recorrência de doenças infecciosas, como SRAG e H1N1, e seu impacto cada vez maior na sociedade têm promovido o estudo de estratégias para frear o seu espalhamento. Muitos estudos teóricos são orientados para estabelecer como as estratégias podem manter o funcionamento da sociedade com o menor impacto econômico. Neste trabalho selecionou-se em algumas destas estratégias para simular e entender o seu impacto no combate às doenças respiratórias, são elas:

- Isolamento Vertical: Nesta estratégia apenas alguns grupos são selecionados para estar em isolamento. Em geral, são grupos mais suscetíveis à infecção que está se espalhando no momento ou grupos com maior probabilidade de transmissão.
- Isolamento Horizontal: Na estratégia de isolamento horizontal todos os indivíduos da população devem se isolar independente da chance de desenvolver ou espalhar a doença.
- Isolamento de Sintomáticos: Nesta estratégia, como o próprio nome diz, a ideia é que os indivíduos da população sejam isolados a partir do momento que manifestarem os sintomas da doença.

- Testagem dos Circulantes: Esta estratégia se assemelha a anterior com a diferença que os indivíduos serão testados e poderão ser isolados caso estejam infectados, mesmo que não apresentem os sintomas.

3. Resultados

O modelo computacional foi implementado no software Netlogo 6. A Figura 3.1 apresenta a tela do modelo no Netlogo. À esquerda são apresentados os comandos para ajuste dos parâmetros e políticas não farmacológicas para o enfrentamento da doença, já ao centro, há uma tela que permite a animação dos agentes, o qual as casas são indicadas por uma coloração marrom e os agentes variam sua coloração dependo do seu estado corrente (ver Tabela 1). Por fim, à direita, são apresentados os gráficos e indicadores que plotam a evolução doença ao longo do tempo simulado.

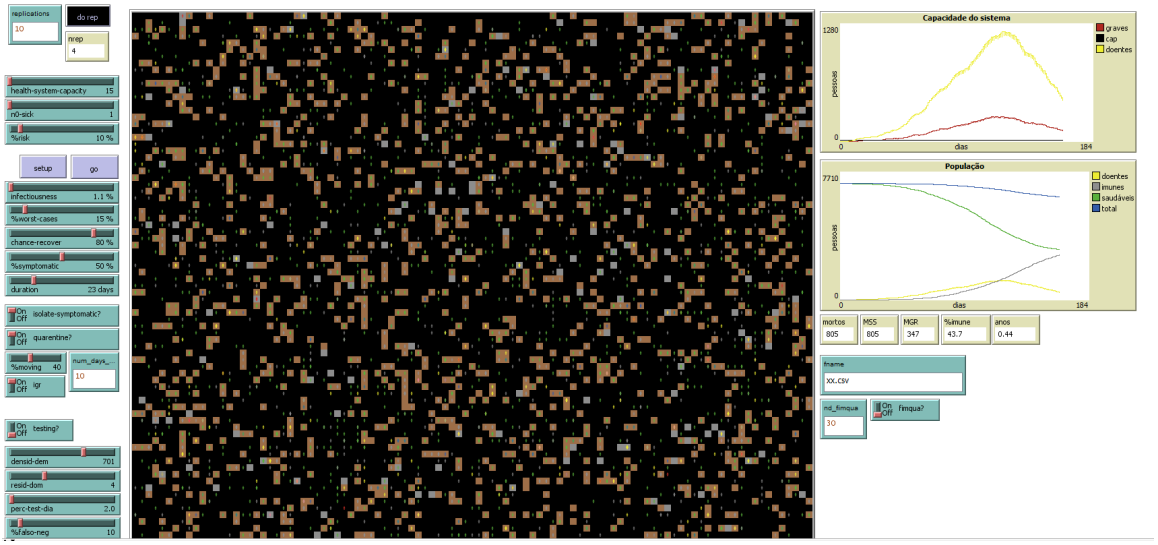


Figura 3.1: Modelo implementado no software Netlogo.

3.1. Definição de Cenários

Para a realização dos experimentos computacionais simulados foram definidos um conjunto de cenários de interesse, baseados em estratégias adotadas por diversos órgãos governamentais de saúde no mundo, não necessariamente dissociadas ou exclusivas, visando combater eficientemente as SRAGs. A Tabela 2 sumariza a simbologia adotada para caracterização das diferentes ações não farmacológicas adotadas em cada um dos cenários simulados.

A nomenclatura apresentada na Tabela 2 foi definida pensando nas diferentes possibilidades de implementação das medidas de combate epidemiológico, seja individual ou combinadas em dado um intervalo de tempo simulado. Assim, um hipotético cenário denominado $VT0.1_s$ seria a combinação das ações V e T, com 0.1% da população testada diariamente, por exemplo. De acordo com a Nota Técnica do Instituto de Estudos para Políticas de Saúde [Rache et al., 2020], o número de leitos no Brasil é em média de 15,6 leitos por 100 mil habitantes. Sendo assim, a capacidade de atendimento foi fixada em 15 indivíduos, simultaneamente, número mais que suficiente para o atendimento da população simulada em condições normais. Ademais, o tamanho da população é de 7010 habitantes. Um total de 17 diferentes cenários foram simulados, são eles:

Tabela 2: Ações não farmacológicas utilizadas nos cenários de teste.

Símbolo	Descrição	Atributos das variações
N	Nenhuma medida de combate é implementada	-
V	Isolamento Vertical	-
H	Isolamento Horizontal	% da população circulando (m) Tempo até o início do isolamento (t)
A	Flexibilização antecipada das medidas	% da população circulando (m) Tempo até o início do isolamento (t) Tempo de isolamento (d)
T	Realização de um % de testes na população	% da população testada diariamente (s)

- $A10_m10_t30_d$ e $A30_m10_t30_d$, em que as medidas de isolamento são flexibilizadas antecipadamente, a porcentagem de circulantes é respectivamente de 10% e 30%, e o tempo de isolamento até a flexibilização em ambos os casos é de 30 dias;
- $H10_m10_t$, $H20_m10_t$, $H20_m20_t$, $H20_m30_t$, $H30_m10_t$, $H40_m10_t$ e $H5_m10_t$, em que é realizado o isolamento horizontal, a porcentagem de circulantes varia entre 5%, 10%, 20%, 30% e 40% e o tempo até o início do isolamento varia entre 10, 20 e 30;
- $HT5_m10_t0.1_s$, $HT5_m10_t0.1_s$, $HT10_m10_t0.1_s$, $HT30_m10_t0.1_s$ e $HT30_m10_t2_s$, em que são adotadas medidas de isolamento horizontal combinada com a testagem da população, a porcentagem de circulantes de 5%, 10% ou 30%, o tempo até o início do isolamento é sempre 10 dias e a porcentagem da população testada diariamente é 0.1% ou 2%.
- N, em que não se toma nenhuma medida de contenção;
- $T0.1_s$, em que a porcentagem da população testada é 0.1%;
- V, em que são isolados somente os indivíduos pertencentes ao grupo de risco;

Todos os cenários executados iniciam com apenas um doente e 10% da população pertencente ao grupo de risco. A doença simulada possui taxa de infecção de 1%, tem duração de 23 dias, 12% dos infectados apresentam quadros graves além do grupo de risco, 80% dos quadros graves se recuperam, 50% dos infectados apresentam sintomas e o vírus sobrevive no ambiente por três dias. A densidade demográfica é de 700 hab/km^2 e o número médio de residentes por domicílio é 4. Além disto, em caso de testagem, o teste tem resultado rápido e pode apresentar 10% de falso positivo e 20% de falso negativo. Para medir o desempenho de cada estratégia adotada foram utilizados três parâmetros, tempo até o fim da pandemia, número de infectados e número de mortos.

3.2. Experimentos computacionais

Os experimentos foram realizados em um computador com 4 processadores AMD Ryzen 3 2200G de 3.5GHz e quatro núcleos cada, com 6GB de RAM e rodando sistema operacional Windows 10. Para cada cenário foram executadas 100 replicações e os dados analisados pelo software R.

As Figuras 3.2 e 3.3 apresentam a difusão esperada para o caso base (N) e para o cenário de melhor desempenho ($H5_m10_t$), respectivamente. São apresentados o número de casos (linha preta) e o número de casos graves (linha vermelha) esperados, por dia, ao longo da epidemia. O

intervalo de confiança de 95% para média dos indicadores é apresentado através da região sombreada. É possível notar que, tomando como referência a capacidade do sistema de tratar doentes graves (linha azul tracejada), o desempenho do cenário $H5_m10_t$ é muito bom por não sobrecarregar o sistema de saúde, o que comprova a eficiência das medidas de controle aplicadas principalmente quando comparado ao cenário N.

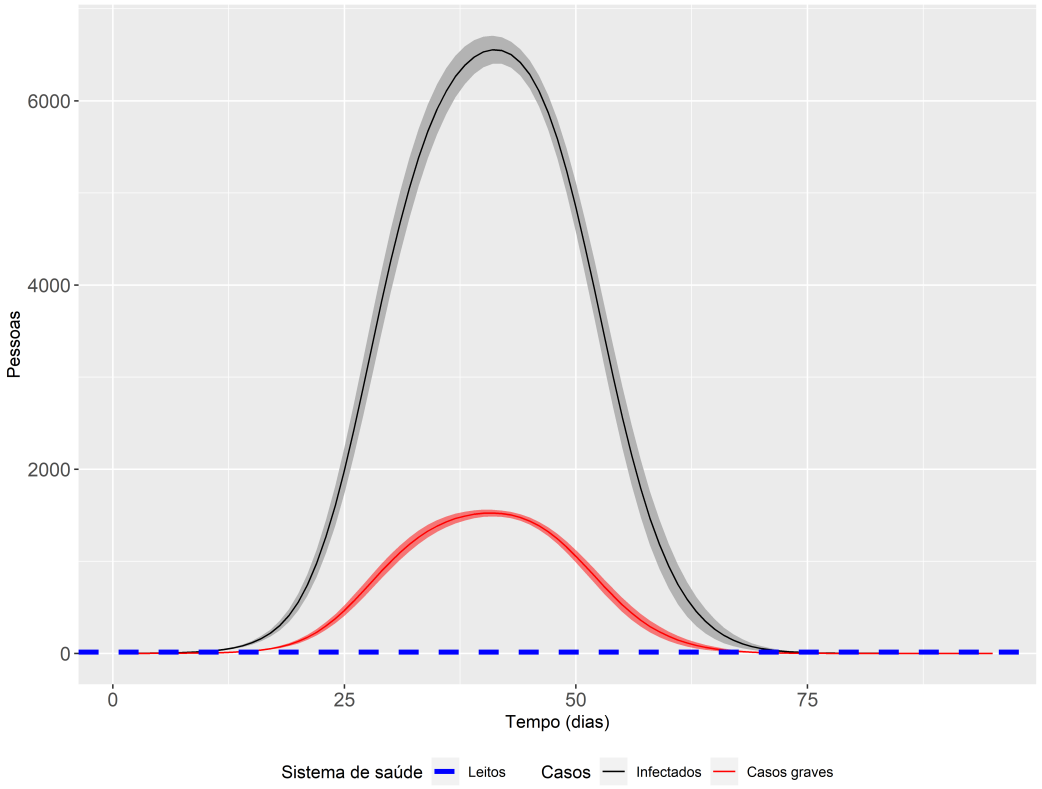


Figura 3.2: Difusão para o caso base (N)

A Figura 3.4 apresenta o desempenho geral para alguns dos cenários. O eixo y indica a quantidade de óbitos do cenário, o eixo x a duração da epidemia e o tamanho do ponto representa o percentual da população infectada. O intervalo de confiança do número de óbitos e da duração da epidemia é representado pela linhas de erro vertical e horizontal, respectivamente. Pela Figura 3.4 é possível notar a eficiência dos cenários de isolamento horizontal (H) frente ao isolamento vertical (V). Nota-se também, o impacto negativo de uma saída prematura do isolamento social (A), bem como o aumento da mobilidade nos cenários de isolamento. Verifica-se que aumento da mobilidade implica em uma duração maior da epidemia, além de elevar a quantidade de óbitos.

A Figura 3.5 detalha o desempenho das replicações do cenário $H40_m10_t$. É importante observar que a variabilidade é grande neste cenário e que o desempenho depende muito das características e comportamento dos primeiros infectados. É um cenário que está fora do controle, isto é, de grande dispersão e sem representatividade da média. Outro ponto a ser observado é o tempo necessário para o fim da epidemia, que pode chegar a 600 dias, neste cenário.

A Tabela 3 sumariza os resultados de todos os cenários executados. Destacados em azul estão os quatro melhores cenários para cada indicador de desempenho e em vermelho os três piores

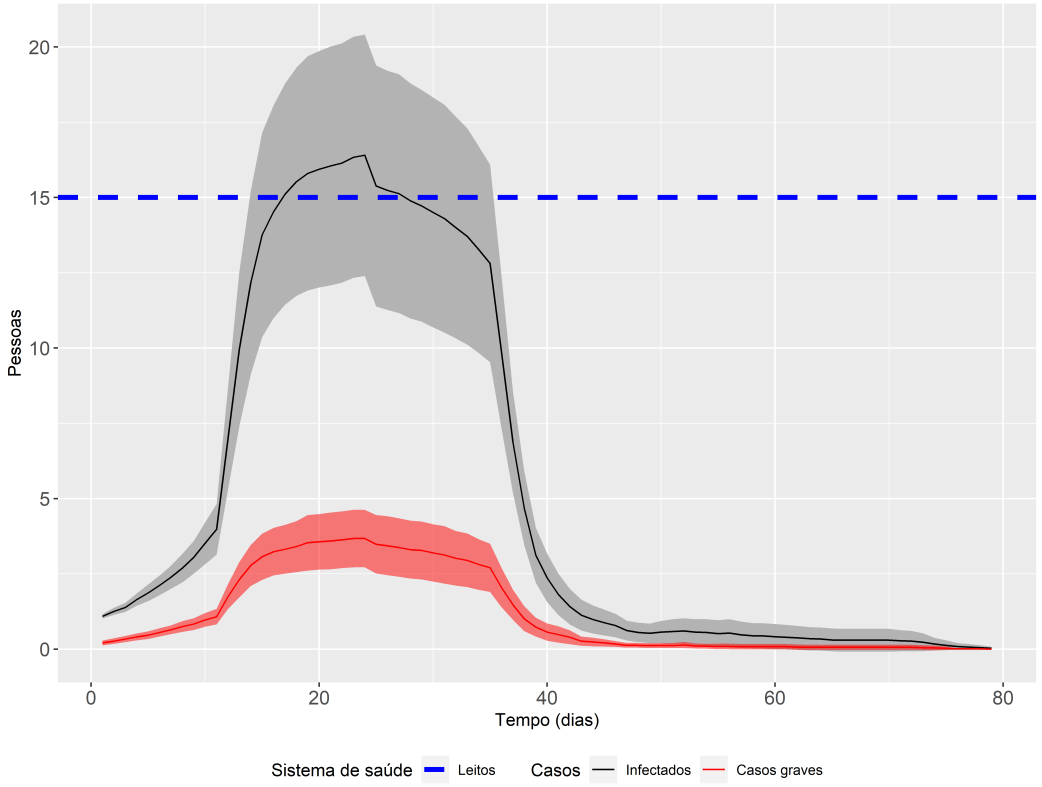


Figura 3.3: Difusão para o melhor caso ($H5_m10_t$)

casos. Comparando os cenários $H20_m10_t$, $H20_m20_t$, $H20_m30_t$ e $H30_m10_t$ é possível observar uma piora no desempenho do cenário (H) quando o tempo para o início do isolamento social aumenta. Contudo, o aumento da mobilidade possui impacto negativo mais significativo.

A determinação da proporção de infectados ao final de uma epidemia depende fortemente do *número básico de reprodução*, denotado R_0. Este número representa quantas novas infecções um caso produziria em uma população composta apenas por indivíduos susceptíveis [Vynnycky e White, 2010, p. 77]. A Tabela 3 apresenta os valores de R_0 de cada cenário calculado através do método proposto por [Dietz, 1993], utilizando o pacote `R0` (em sua versão 1.2-6) do *software* R. Em todos os cenários, o valor de R_0 é maior do que 1 e, no caso base, de 7.83, valor elevado e maior do que os valores estimados para a Covid-19 que variam de 1.94 à 5.7 [Li et al., 2020; D'Arienzo e Coniglio, 2020; Riou e Althaus, 2020; Wu et al., 2020; Sanche et al., in press 2020].

A comparação dos cenários $H5_m10_t$, $H10_m10_t$, $H20_m10_t$, $H30_m10_t$ e $H40_m10_t$ demonstra que embora o isolamento horizontal seja uma política eficiente, é necessário que a mobilidade seja mantida em valores baixos para sua efetividade. Os cenários $H5_m10_t2_s$ e $H5_m10_t0.1_s$, juntamente com o $H5_m10_t$, apresentam os melhores desempenho nos três indicadores. Além disto, destaca-se a variabilidade e a duração da epidemia nos cenários $H40_m10_t$, $H30_m10_t$ e $H20_m30_t$ que apresentam os piores desempenhos em termos de duração da epidemia.

A aplicação de testes por amostragem demonstrou ser eficiente quando realizada em larga escala (2% da população por dia) e quando associada à medida de isolamento horizontal (cenários $H5_m10_t2_s$ e $HT30_m10_t2_s$). Por outro lado, sozinha e em baixa proporção ($T0.1_s$) ela não possui

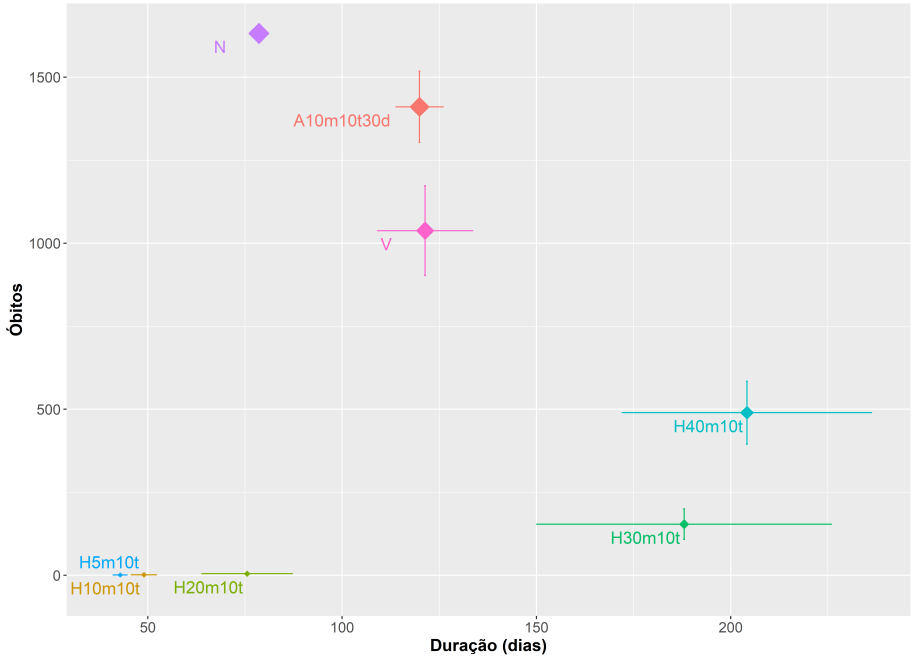


Figura 3.4: Comparação de alguns cenários simulados

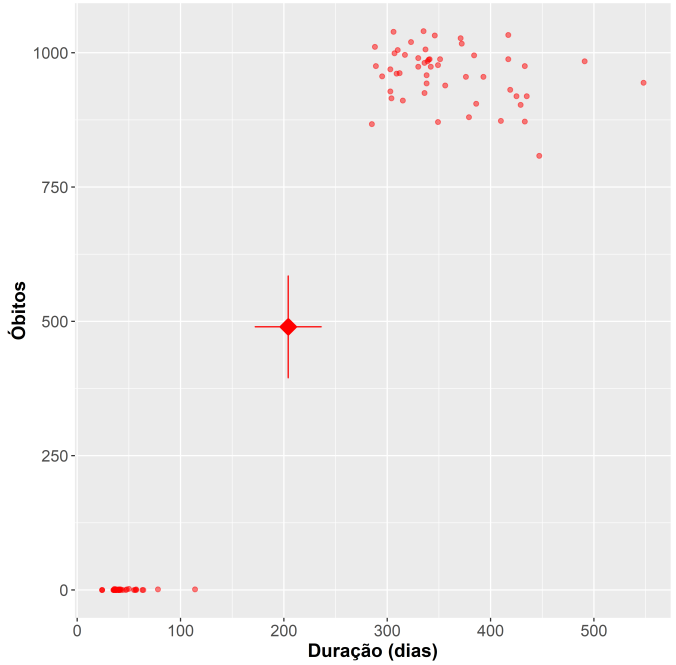


Figura 3.5: Replicações do Cenário $H40_m10_t$

um desempenho satisfatório.

Nos casos em que avaliou-se o abandono prematuro do isolamento horizontal, foi constatado um péssimo desempenho, mesmo quando associado a cenários de controle mais rígidos

Tabela 3: Cenários simulados considerando uma população total é de 7010 indivíduos e 100 replicações.

Cenário	R_0	Tempo (dias)		% de infectados		% de mortos		Indicadores de desempenho		
		$\bar{x}$	σ	$\bar{x}$	σ	$\bar{x}$	σ	Tempo	Infectados	Mortes
$A10_m10_t30_d$	2.33	119.91	31.66	86.76	33.62	20.12	7.83	0.58	0.87	0.86
$A30_m10_t30_d$	2.96	117.97	22.15	93.70	23.78	21.92	5.59	0.57	0.94	0.94
$H10_m10_t$	1.00	48.99	17.13	0.31	0.37	0.02	0.05	0.24	< 0.01	< 0.01
$H20_m10_t$	1.00	75.55	59.95	0.73	1.21	0.07	0.16	0.36	< 0.01	< 0.01
$H20_m20_t$	1.01	107.91	70.92	2.00	2.84	0.35	0.67	0.52	0.02	0.01
$H20_m30_t$	1.03	147.15	102.94	5.78	6.91	1.32	1.83	0.71	0.06	0.06
$H30_m10_t$	1.05	188.00	194.01	8.92	13.05	2.20	3.34	0.90	0.09	0.09
$H40_m10_t$	1.17	204.17	164.25	27.79	27.38	6.99	6.90	0.98	0.28	0.30
$H5_m10_t$	1.00	42.88	9.66	0.22	0.28	0.01	0.04	0.21	< 0.01	< 0.01
$HT5_m10_t0.1_s$	1.00	42.10	8.82	0.26	0.32	0.02	0.05	0.20	< 0.01	< 0.01
$HT5_m10_t2_s$	1.00	41.18	4.95	0.21	0.24	0.01	0.02	0.20	< 0.01	< 0.01
$HT10_m10_t0.1_s$	1.00	43.00	7.88	0.23	0.23	0.01	0.03	0.21	< 0.01	< 0.01
$HT30_m10_t0.1_s$	1.02	126.00	119.36	3.13	5.71	0.65	1.43	0.61	0.03	0.03
$HT30_m10_t2_s$	1.00	54.55	17.31	0.33	0.40	0.03	0.07	0.26	< 0.01	< 0.01
N	7.83	78.58	5.61	99.96	0.02	23.28	0.44	0.38	1.00	1.00
$T0.1_s$	1.59	125.53	67.20	63.85	44.01	14.97	10.33	0.60	0.64	0.64
V	1.65	121.35	63.03	66.57	43.81	14.80	9.83	0.58	0.67	0.64
Máximo		207.79	211.22	99.96	44.01	23.28	10.33			
Mínimo		41.18	4.95	0.21	0.02	0.01	0.02			

* Valores médios normalizados pelo pior caso ou $\frac{\bar{x}}{\bar{x}_{\text{Máximo}}}$.

($A10_m10_t30_d$ e $A10_m10_t30_d$). Estes cenários apresentam os piores desempenhos em termos de número de infectados e mortos, quando descartado o cenário N. Vale ressaltar ainda que o isolamento vertical é melhor que o caso base (N), embora não tenha apresentado um desempenho satisfatório.

4. Considerações Finais

O trabalho apresentou uma ferramenta completa, capaz de simular, descrever e estimar o desempenho de medidas não farmacológicas de controle de endemias virais em uma pequena região geográfica. Os resultados dos testes realizados mostraram a importância das medidas de isolamento social e de testagem por amostragem tanto para a minimização do número de óbitos, quanto para minimização da duração da circulação do vírus.

No momento em que essa conclusão está sendo escrita, o Brasil apresenta cerca de 391 mil casos confirmados de Covid-19 com 24 mil óbitos reportados, o dobro em relação a semana anterior. No presente momento as medidas de isolamento social estão sendo questionadas em diversas partes do país e em diferentes esferas de governo. O modelo proposto se mostra sensível aos parâmetros de entrada e se comporta como o esperado, de acordo com a literatura. A conclusão a respeito da eficácia de uma medida não pode ser generalizada. Pode-se, entretanto, generalizar a eficiência relativa entre as medidas. Embora os dados da doença simulados não necessariamente correspondam à Covid-19, o comportamento exponencial de crescimento do número de casos está bem representado, tal como o efeito que as medidas não farmacológicas possuem sobre o crescimento.

Sabe-se, no entanto, que a realidade se dará por uma mudança constante das aplicações de medidas não farmacológicas de controle, tendo como referência a resposta em termos do desempenho, isto é, a aplicação de tais medidas se dará de forma dinâmica ao longo da duração da pandemia. Como limitações do trabalho, o modelo poderia considerar os fluxos de deslocamento

de forma mais realista além de considerar população transeunte no local analisado. Outras medidas de controle como barreira sanitária e medição de temperatura em massa poderiam, também, ser consideradas.

Em trabalhos futuros pretende-se construir um modelo mais completo, hierárquico, para simular grandes regiões geográficas. Pretende-se combinar Simulação de Monte Carlo, Simulação Baseada em Agentes, Aprendizado de Máquina e Sistemas de Informações Geográficas (SIGs) com foco na disseminação e permanência do vírus no ambiente por meio de dados reais da propagação de SRAGs, dados demográficos, socioeconômicos, sanitários e da capacidade do sistema de saúde de uma determinada região.

Agradecimentos

Os autores gostariam de agradecer à CAPES, ao CNPq, à FAPEMIG e à UFOP pelo apoio ao desenvolvimento deste projeto.

Referências

Arifin, S. M. N., Madey, G. R., e Collins, F. H. (2016). *Spatial Agent-Based Simulation Modeling in Public Health*. Wiley Series in Modeling and Simulation. Wiley, New Jersey, 1 edition. ISBN 978-1-118-96435-4.

D'Arienzo, M. e Coniglio, A. (2020). Assessment of the sars-cov-2 basic reproduction number, r0, based on the early phase of covid-19 outbreak in italy. *Biosafety and Health*.

Dietz, K. (1993). The estimation of the basic reproduction number for infectious diseases. *Statistical methods in medical research*, 2(1):23–41.

Ferguson, N. M., Laydon, D., Nedjati-Gilani, G., Imai, N., Ainslie, K., Baguelin, M., Bhatia, S., Boonyasiri, A., Cucunubá, Z., Cuomo-Dannenburg, G., Dighe, A., Dorigatti, I., Fu, H., Gaythorpe, K., Green, W., Hamlet, A., Hinsley, W., Okell, L. C., van Elsland, S., Thompson, H., Verity, R., Volz, E., Wang, H., Wang, Y., Walker, P. G. T., Walters, C., Winskill, P., Whittaker, C., Donnelly, C. A., Riley, S., e Ghani, A. C. (2020). Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand. *Imperial College COVID-19 Response Team*, p. 1–20. URL `https://www.imperial.ac.uk/media/imperial-college/medicine/sph/ide/gida-fellowships/Imperial-College-COVID19-NPI-modelling-16-03-2020.pdf`. Acessado: 2020-04-25.

Heppenstall, A., Crooks, A., See, L. M., e Batty, M., editors (2012). *Agent-Based Models of Geographical Systems*. Springer Netherlands, Dordrecht, 1 edition. ISBN 978-90-481-8927-4.

Ivanov, D. (2020). Predicting the impacts of epidemic outbreaks on global supply chains: A simulation-based analysis on the coronavirus outbreak (COVID-19/SARS-CoV-2) case. *Transportation Research Part E: Logistics and Transportation Review*, 136:101922. ISSN 1366-5545. URL `http://www.sciencedirect.com/science/article/pii/S1366554520304300`. Acessado: 2020-04-19.

Lana, R. M., Coelho, F. C., Gomes, M. F. d. C., Cruz, O. G., Bastos, L. S., Villela, D. A. M., e Codeço, C. T. (2020). Emergência do novo coronavírus (SARS-CoV-2) e o papel de uma

vigilância nacional em saúde oportuna e efetiva. *Cadernos de Saúde Pública*, 36. ISSN 0102-311X. URL http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-311X2020000300301&nrm=iso. Acessado: 2020-04-24.

Li, Q., Guan, X., Wu, P., Wang, X., Zhou, L., Tong, Y., Ren, R., Leung, K. S., Lau, E. H., Wong, J. Y., et al. (2020). Early transmission dynamics in wuhan, china, of novel coronavirus–infected pneumonia. *New England Journal of Medicine*.

Rache, B., Rocha, R., Nunes, L., Spinola, P., Malik, A. M., e Massuda, A. (2020). *Necessidades de Infraestrutura do SUS em Preparo ao COVID-19: Leitos de UTI, Respiradores e Ocupação Hospitalar*. Nota Técnica, n.3, IEPS, São Paulo. URL http://www.saude.mppr.mp.br/arquivos/File/Corona/Txt_Sanitarios/Necessidades_infra_SUS.pdf. Acessado: 2020-05-15.

Riou, J. e Althaus, C. L. (2020). Pattern of early human-to-human transmission of wuhan 2019 novel coronavirus (2019-ncov), december 2019 to january 2020. *Eurosurveillance*, 25(4):2000058.

Sanche, S., Lin, Y. T., Xu, C., Romero-Severson, E., Hengartner, N., e Ke, R. (in press 2020). Eid: High contagiousness and rapid spread of severe acute respiratory syndrome coronavirus 2. *Emerging Infectious Diseases*.

Siegfried, R. (2014). *Modeling and Simulation of Complex Systems*. Springer Vieweg, Wiesbaden, 1 edition. ISBN 978-3-658-07529-3.

Taylor, S., editor (2014). *Agent-based Modeling and Simulation*. OR Essentials. Palgrave Macmillan, London, 1 edition. ISBN 978-1-137-45364-8.

Valdez, L. D., Buono, C., Macri, P. A., e Braunstein, L. A. (2013). Social distancing strategies against disease spreading. *Fractals*, 21(03n04):1350019. ISSN 0218-348X. URL https://doi.org/10.1142/S0218348X13500199. Acessado: 2020-04-30.

Vynnycky, E. e White, R. G. (2010). *An Introduction to Infectious Disease Modelling*. Oxford University Press, EUA, 1 edition. ISBN 978-0-19-856576-5.

Wu, J. T., Leung, K., Bushman, M., Kishore, N., Niehus, R., de Salazar, P. M., Cowling, B. J., Lipsitch, M., e Leung, G. M. (2020). Estimating clinical severity of covid-19 from the transmission dynamics in wuhan, china. *Nature Medicine*, 26(4):506–510.