





Avaliação de estratégias de relaxamento do distanciamento social para o Brasil e Estado do Rio de Janeiro

Diego T. Volpatto ^{a,*}, Anna Claudia M. Resende ^a, Lucas dos Anjos ^a, João V. O. Silva ^a, Claudia M. Dias ^b, Regina C. Almeida ^a e Sandra M. C. Malta ^a

^aLNCC, Laboratório Nacional de Computação Científica, Petrópolis, RJ, Brasil; ^bUFRRJ, Universidade Federal Rural do Rio de Janeiro, Nova Iguaçu, RJ, Brasil

Nota técnica escrita em 23 de Maio de 2020

Nesta nota técnica discutimos algumas medidas de relaxamento do distanciamento social e seus impactos no sentido epidemiológico, com o objetivo de avaliar os efeitos nas projeções da epidemia da COVID-19 no Brasil e, em particular, no Estado do Rio de Janeiro. A análise de possíveis cenários de relaxamento do distanciamento social é tema de grande relevância para auxiliar a estimar o momento mais apropriado para o retorno à normalidade do cotidiano. Neste contexto, discutimos a importância – e as possíveis consequências – de realizar o relaxamento do distanciamento social em um momento adequado. Os resultados indicam que a adoção de medidas de relaxamento gradual do distanciamento social, quando em situação de controle epidemiológico, são viáveis. Por outro lado, na ausência de verificação de controle epidemiológico, tanto medidas de relaxamento gradual quanto abruptas geram substancial aumento no número de casos confirmados e óbitos, além de evidências de considerável aumento no tempo necessário para a erradicação da doença. Portanto, no cenário em que não é possível aferir o controle epidemiológico, as medidas de relaxamento do distanciamento social estudadas nesta pesquisa não são recomendadas.

Distanciamento Social | COVID-19 | SARS-CoV-2 | Modelos Compartimentais

No final de 2019, o mundo foi tomado pelas notícias sobre o surto de um novo coronavírus chamado SARS-CoV-2, que é a sigla para Coronavírus da Síndrome Respiratória Aguda Grave 2 em inglês. A doença associada foi denominada como COVID-19 pela Organização Mundial da Saúde (OMS). Em 11 de Março de 2020, a OMS declara estado de pandemia, alertando sobre os perigos dessa nova doença. Uma linha do tempo resumida sobre as ações da OMS no estágio inicial da epidemia do COVID-19 é disponibilizada on-line (1). Buscando mitigar a doença e a sobrecarga em sistemas de saúde, alternativas foram buscadas e estudos preliminares sugeriram medidas de distanciamento social como forma de amenizar a propagação da doença e “achatar a curva” (2–4). Medidas desse tipo são denominadas políticas de intervenção não-farmacológicas (5), sendo estratégias viáveis no sentido de conter a propagação de doenças contagiosas na ausência de tratamento farmacológico comprovado. Em uma análise de 11 países europeus, um relatório publicado pelo *Imperial College London* sugere a eficácia observada do distanciamento social como medida para diminuição da propagação da COVID-19 (6). Neste contexto, baseando-se na literatura científica, diversos países adotaram esse tipo de medida em algum grau. No entanto, inevitavelmente, a doença se espalhou pelo planeta (ver Figura 1) marcando a história da humanidade como uma calamidade sanitária.

No Brasil o primeiro caso de COVID-19 foi confirmado em 26 de fevereiro de 2020, em São Paulo. A evolução de casos e óbitos registrados ocorreu rapidamente em território nacional. Um mês após o primeiro caso confirmado já eram registrados 2915 infectados e em dois meses se contabilizavam mais de 62 mil casos e 4.244 óbitos no país. No momento em que essa nota técnica foi escrita, o Brasil somava 330.890 casos e 21.048 óbitos, sendo um dos países com maior número de casos confirmados e mortos no mundo (ver Figuras 3a e 3b). Uma breve linha do tempo da evolução destes números é apresentada na Figura 2, com dados retirados do painel dedicado à epidemia da COVID-19 elaborado pelo Ministério da Saúde (8).

Apesar dos números alarmantes da doença no mundo, medidas de distanciamento social foram gradualmente adotadas no Brasil em várias cidades e Estados na segunda metade do mês de março, pouco tempo após a OMS classificar a COVID-19 como pandemia. No entanto, há poucas notícias de localidades em que medidas rígidas, como o *lockdown* adotado na província de Hubei, na China, tenham sido empregadas até o presente momento. Dessa forma, contando com essa estratégia de distanciamento social, o cenário brasileiro de enfrentamento da pandemia se caracteriza principalmente por:

- Medidas moderadas de distanciamento social;
- Sub-notificação de casos devido ao baixo número de testagens (9, 10).

Contribuições dos autores: DTV, ACMR e JVO realizaram as implementações e simulações computacionais. Todos os autores contribuíram com a concepção, a redação, a revisão e a aprovação da versão final do manuscrito.

Os autores declaram que não há conflitos de interesse.

* Autor de contato. E-mail: volpatto@lncc.br

Casos de COVID-19 registrados até 21/05/2020

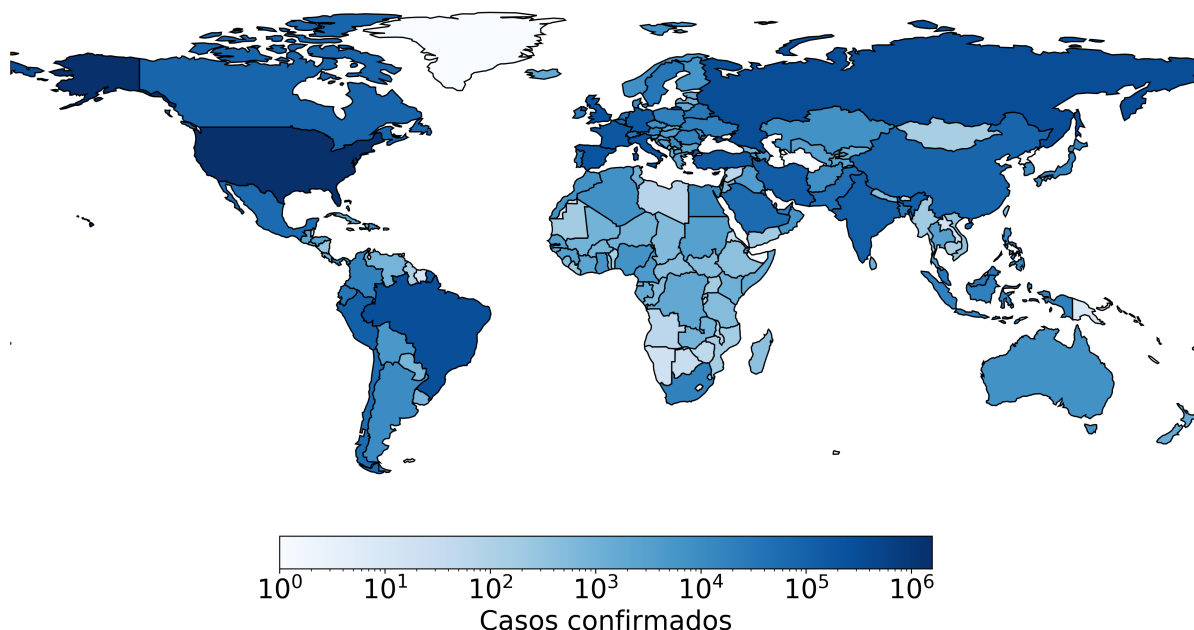


Figura 1. Distribuição mundial dos casos confirmados de COVID-19 até 21/05/2020. Dados retirados de (7).




Figura 2. Linha do tempo da evolução de casos confirmados e total de óbitos para o Brasil.

Do ponto de vista epidemiológico, ambos os aspectos podem apresentar complicações no combate e entendimento da epidemia. Na ausência de intervenções farmacêuticas (controle por vacinas e remédios), o mecanismo mais eficiente para desacelerar a propagação de uma epidemia que se transmite por meio de interações sociais é o distanciamento social (11–13), que pode ter sua eficácia aprimorada quando combinado com a utilização de equipamentos de proteção individual (como máscaras, por exemplo), apesar de alguns estudos apontarem que a evidência do benefício no uso de máscaras na pandemia é insuficiente para o público em geral (14, 15). Dessa forma, o distanciamento social se enquadra como estratégia principal para o controle da doença, com consequências deletérias se implementada de forma inadequada. A sub-notificação, por outro lado, resulta na falta de conhecimento sobre o verdadeiro estágio da epidemia. Isso compromete a elaboração de políticas públicas, assim como o desenvolvimento e aplicação de modelos preditivos e realização de projeções vitais para elaborá-las, prejudicando a avaliação de cenários e tomadas de decisões estratégicas. A principal causa da sub-notificação é a ausência de testes em massa. Apenas muito recentemente foram iniciados planos para testagem mais abrangente no Brasil, como o realizado pela Universidade Federal de Pelotas com o apoio do Ministério da Saúde. Este estudo constatou que 1,4% da população das 90 cidades analisadas apresenta anticorpos, o que corresponde à sete vezes mais que as estatísticas oficiais (16).

Diante do contexto e principais problemas que envolvem a propagação e a mitigação da epidemia da COVID-19 no Brasil, algumas perguntas estratégicas podem ser levantadas:

1. Qual seria o momento crítico da epidemia no Brasil?
2. Existem recursos hospitalares (leitos e insumos) suficientes para todo o período da epidemia?
3. Como tratar a sub-notificação em termos práticos e também preditivos?
4. Como lidar com as incertezas da epidemia?
5. Dado o impacto crítico do distanciamento social, qual seria o momento apropriado para o relaxamento?

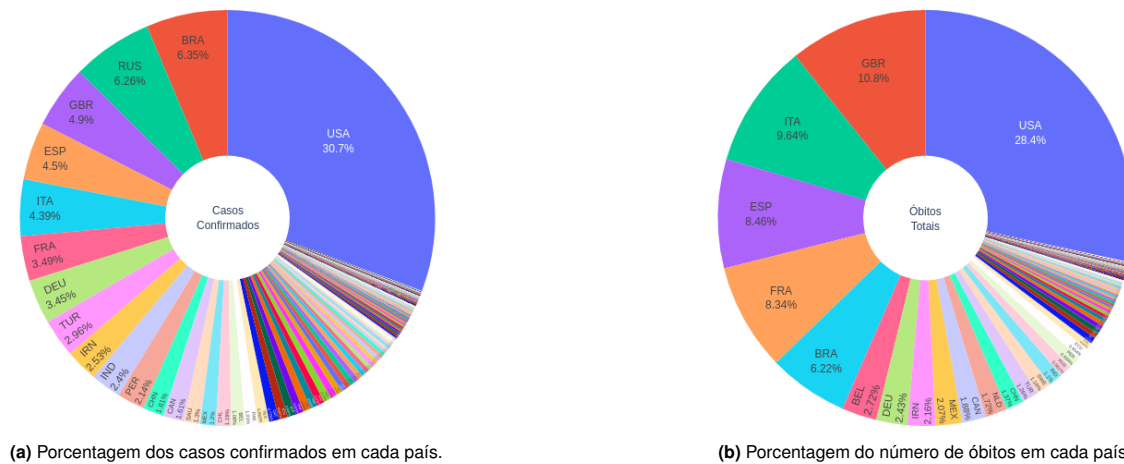


Figura 3. Porcentagens, de cada país, referentes ao número de casos confirmados e óbitos totais no cenário global até 21/05/2020. Dados retirados de (7).

Na tentativa de contribuir para responder à essas perguntas e auxiliar no enfrentamento desse momento crítico e histórico, o grupo autor dessa nota técnica e informativa foi formado. Inicialmente, apresentamos no presente texto análises referentes, principalmente, às perguntas 4 e 5 (as demais serão abordadas em momento oportuno). Atualmente o tema de relaxamento das medidas de distanciamento social é de grande interesse público devido ao impacto na sociedade em vários sentidos, não apenas sanitário. Nesta Nota Técnica (NT), temos por objetivo apresentar de maneira acessível e objetiva algumas avaliações de possíveis cenários de relaxamento e estimar suas consequências. A pergunta que surge, então, é: como avaliar esses cenários? E é nesse contexto que introduziremos o leitor numa abordagem por modelagem matemática e computacional da COVID-19.

Modelando matematicamente a epidemia

Em contextos em que queremos compreender determinados aspectos da realidade que somos capazes de observar, uma ferramenta científica muito poderosa é comumente empregada: a criação de modelos. E o que são esses modelos exatamente? De forma simples e direta, modelos são representações simplificadas da realidade. Note que não necessariamente todos os modelos são matemáticos. Por exemplo, uma maquete é um tipo de modelo. Além disso, não existe o modelo perfeito, que represente a realidade exatamente como ela é, mas existem – e podem ser elaborados – modelos capazes de capturar características observadas específicas (e de interesse) da realidade. É exatamente isso que apresentamos nessa seção, um modelo matemático capaz de capturar características de interesse que desejamos representar da realidade, para assim poder extrair conhecimentos estratégicos que nos auxiliem a entender o comportamento da COVID-19 no Brasil e, em especial, no estado do Rio de Janeiro, e, eventualmente, combatê-la. Então, como esse modelo foi construído e quais são suas premissas? É o que mostraremos a seguir.

Dividindo a população em classes. Queremos criar um modelo que capture a essência da propagação de uma epidemia. Para isso, temos que observar (de acordo com os limites dos nossos conhecimentos) como a realidade se comporta. Resumimos a dinâmica de evolução da doença na Figura 4 buscando ajudar o entendimento. No caso da epidemia do COVID-19, sabemos que é uma doença transmitida por meio de interações entre as pessoas. Quando uma pessoa saudável e sem defesa biológica prévia interage com um indivíduo infectado (sintomático ou assintomático) essa pessoa saudável tem uma *chance* de ser infectada. Caso ela seja infectada, existe um período latente em que a carga viral no organismo não é suficiente para tornar o indivíduo recém infectado em um capaz de transmitir a doença. Denominamos este indivíduo como exposto. No entanto, após passado o período latente, o indivíduo exposto torna-se infectado. Neste ponto, entra uma característica chave da epidemia do COVID-19 (3, 17): indivíduos infectados podem exibir sintomas ou podem ser assintomáticos, ou com sintomas fracos. Levando em conta uma característica chave da presente epidemia (sub-notificação), o indivíduo infectado pode: ser diagnosticado e se tornar, dessa forma, um caso com acompanhamento médico e, eventualmente, se recuperar; ou nunca ser diagnosticado e se recuperar sem acompanhamento médico. Analogamente, tanto o indivíduo diagnosticado (e sob observação) quanto o não-diagnosticado sintomático podem falecer em decorrência da doença. Adicionalmente a essas possibilidades, todos os indivíduos que não estejam sob observação médica (ou seja, sem diagnóstico ou saudáveis) podem estar sujeitos à medidas de distanciamento social, já que não há conhecimento dos indivíduos em período viral latente ou infectados não-diagnosticados (sintomáticos ou assintomáticos), não sendo identificados durante a aplicação da medida. Para os indivíduos diagnosticados, já é admitido que eles serão separados dos demais. É razoável considerar que todos os indivíduos separados devido à implementação do distanciamento social não irão se infectar ou terão uma chance muito menor de serem infectados.

Com base nesse entendimento da evolução do estado de um indivíduo na dinâmica de infecção, associamos esses estados a classes/grupos ou, como comumente denominados na literatura, compartimentos (18, 19). Modelos compartimentais, normalmente denominados como do tipo SIR (Suscetível-Infectado-Recuperado), SEIR (Suscetível-Exposto-Infectado-Recuperado) e derivados, são amplamente empregados no estudo de epidemias, em que a população de interesse, em uma dada localidade, é

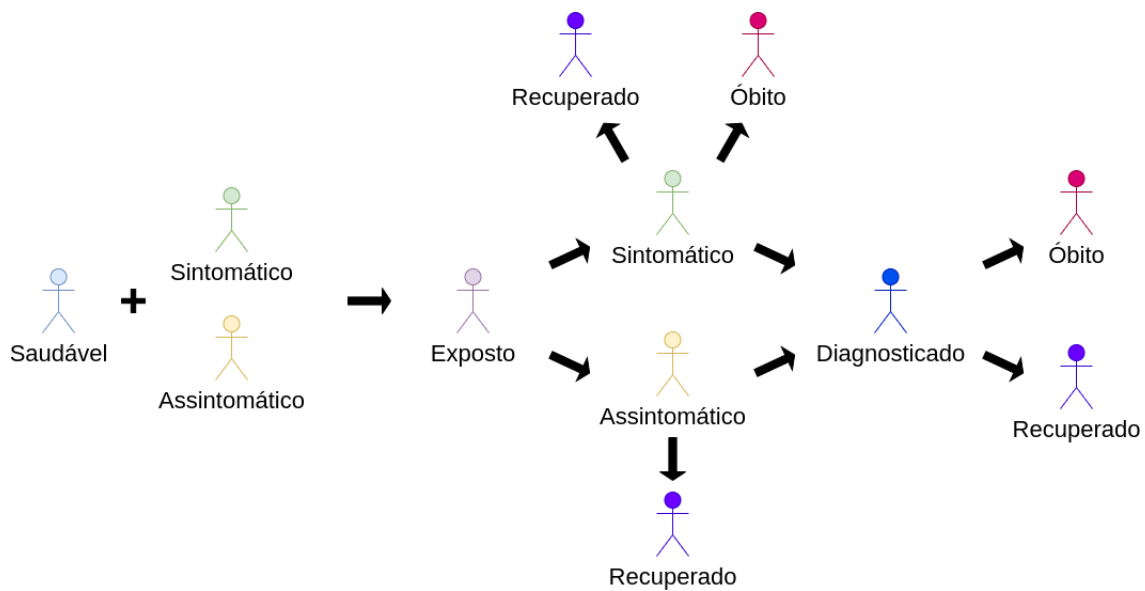


Figura 4. Evolução do estado de um indivíduo inicialmente saudável/suscetível.

Grupo	Descrição
Suscetíveis (S)	Indivíduos que não tiveram contato prévio com a doença e, dessa forma, não são resistentes à infecção.
Expostos (E)	Indivíduos que tiveram contato com infectados (sintomáticos ou assintomáticos) e que carregam o vírus em período latente.
Infectados sintomáticos (I)	Indivíduos que contraíram o vírus e exibem sintomas característicos. São capazes de transmitir a doença.
Infectados assintomáticos (A)	Indivíduos que contraíram o vírus e não exibem sintomas característicos. São capazes de transmitir a doença.
Positivamente diagnosticados (P)	Indivíduos que foram diagnosticados como doentes por COVID-19. Não são capazes de transmitir a doença pois foram isolados após o diagnóstico.
Removidos (R)	Indivíduos vivos que não participam mais da dinâmica de infecção. Esta classe é composta por recuperados (vindos de I, A e P) e também por suscetíveis e expostos que estão em distanciamento social.
Mortos (D)	Indivíduos que faleceram devido à doença.

Tabela 1. Compartimentos ou grupos de indivíduos considerados.

divida em compartimentos. Tomando como base esse tipo de modelagem, temos como objetivo construir um modelo capaz de representar as interações e relações entre os grupos descritos na Tabela 1.

Sistemas dinâmicos compartimentais. Com população de uma localidade dividida nos compartimentos citados, nos falta elaborar a representação de como esses compartimentos se relacionam entre si. No presente estudo, adotamos a modelagem por equações diferenciais ordinárias, porém é válido ressaltar que outras abordagens são possíveis. Por exemplo, modelos baseados em agentes, como proposto por outro grupo de pesquisadores do LNCC (20).

Postulamos um sistema dinâmico no qual é computada a variação temporal da quantidade de indivíduos em cada compartimento, que ocorre por consequência de transformações ou mudanças de indivíduos entre os compartimentos. Dessa maneira, as interações e transformações dos indivíduos ocorrem de acordo com certas taxas. O esquema do nosso modelo – denominado de SEAIRPD-Q devido à sua composição, e seu equacionamento são exibidos na Figura 5. Os blocos representam os compartimentos de indivíduos das diferentes classes, enquanto que as setas representam os mecanismos que levam à mudança de indivíduos de um dado compartimento para outro. Junto à cada linha das setas, indicamos as taxas envolvidas no mecanismo correspondente. É importante notar que a transformação de indivíduos suscetíveis (S) em indivíduos expostos (E) ocorre por meio de interação com indivíduos dos grupos de infectados (I e A) de acordo com taxas β e μ . O restante dos mecanismos são dependentes apenas de taxas, sem envolver outros compartimentos. Outro fator importante de se notar no modelo é o mecanismo que descreve a aplicação do distanciamento social, representado como uma taxa média de remoção ω dos compartimentos S , E , A e I . Dessa forma, é possível excluir esses indivíduos removidos da dinâmica de infecção. Abordagem similar foi adotada em (12). Ressaltamos que optamos por fazer uma abordagem de quarentena/distanciamento social implícita, isto é, não modelamos um compartimento específico que contabiliza apenas os indivíduos em quarentena, ao contrário de outros trabalhos (2, 3). A vantagem dessa representação implícita é obter um modelo mais compacto, com menor número de equações, o que pode auxiliar na diminuição do custo computacional da simulação do modelo e na estimação dos seus parâmetros. Para completar a formulação, um breve resumo do significado epidemiológico dos parâmetros do modelo é disponibilizado na Tabela

2.

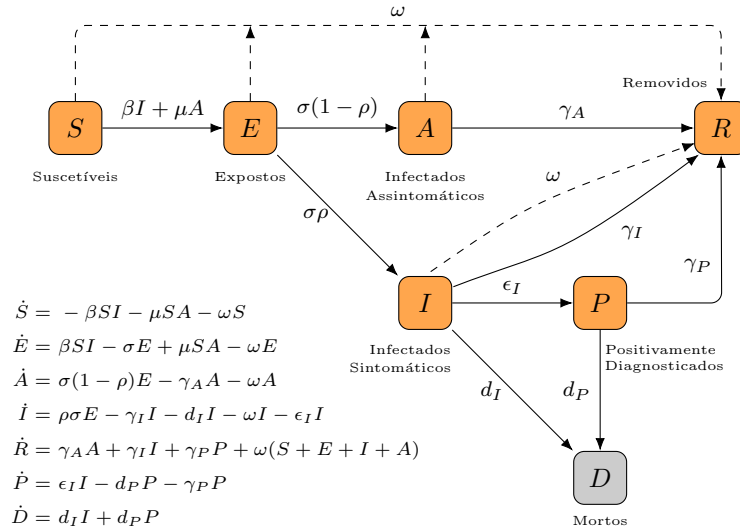


Figura 5. Esquema do modelo SEAIRPD-Q e seu equacionamento.

Parâmetro	Significado
β	Taxa de transmissão devido ao contato com indivíduos infectados sintomáticos
μ	Taxa de transmissão devido ao contato com indivíduos infectados assintomáticos
$1/\sigma$	Tempo médio de transição de indivíduos expostos para infectados
ρ	Proporção de indivíduos infectados sintomáticos em relação ao número total de infectados ($I + A$)
$1/\epsilon_I$	Tempo médio de diagnóstico de indivíduos com acompanhamento médico
$1/\gamma_A$	Tempo médio de recuperação de indivíduos infectados assintomáticos
$1/\gamma_I$	Tempo médio de recuperação de indivíduos infectados sintomáticos
$1/\gamma_P$	Tempo médio de recuperação de indivíduos com acompanhamento médico
d_I	Taxa de mortalidade de indivíduos infectados sintomáticos
d_P	Taxa de mortalidade de indivíduos diagnosticados
ω	Taxa de remoção de indivíduos em S, E, A e I devido à aplicação de distanciamento social

Tabela 2. Breve significado epidemiológico dos parâmetros do modelo SEAIRPD-Q.

Avaliando o estado da epidemia - o cálculo do número de reprodução. A partir do modelo compartimental SEAIRPD-Q, uma das formas de avaliar a capacidade de disseminação e controle da doença é analisando o número de reprodução (21, 22), que indica o número de indivíduos que uma pessoa infectada irá contagiar. Denotamos como \mathcal{R}_0 e $\mathcal{R}(t)$ o número de reprodução basal e o número de reprodução efetivo, respectivamente, com t sendo a variável que representa o tempo. O \mathcal{R}_0 é um valor determinado no início da epidemia, enquanto que $\mathcal{R}(t)$ captura os efeitos da evolução da epidemia a partir do valor inicial de $\mathcal{R}(t = 0) \equiv \mathcal{R}_0$. Esses números têm um significado prático muito importante. Quando $\mathcal{R}(t) > 1$, a epidemia continua a se propagar. Em caso contrário, quando $\mathcal{R}(t) < 1$, será observado o controle da epidemia, diminuindo a disseminação e, após decorrer tempo suficiente, a erradicação da doença. No presente trabalho, baseando-se em (23), calculamos o número de reprodução efetivo como:

$$\mathcal{R}(t) := \left[\frac{\sigma(1-\rho)\mu}{(\sigma + \omega)(\gamma_A + \omega)} + \frac{\beta\sigma\rho}{(\sigma + \omega)(\gamma_I + d_I + \omega + \epsilon_I)} \right] S(t).$$

Simulação de estratégias de relaxamento do distanciamento social

Nesta seção, a partir do modelo SEAIRPD-Q vamos avaliar o efeito de medidas de manutenção e relaxamento da política de distanciamento social em vigor, adotando o Brasil (em escala nacional) e o Estado do Rio de Janeiro como localidades de interesse. As análises são pautadas em avaliações qualitativas dos cenários, já que incertezas e simplificações estão presentes. Não obstante, essas limitações não invalidam o estudo dos efeitos dos mecanismos que envolvem o distanciamento social aqui considerado, provendo conhecimento que pode ser utilizado a favor de tomadas de decisões estratégicas.

Identificação dos parâmetros do modelo e tratamento de incertezas com os dados disponíveis. Para proceder com a realização de predições, antes é necessário ajustar o modelo de acordo com o que já foi observado, isto é, os dados disponíveis. Esse procedimento é geralmente denominado de *Calibração*. Essa é uma etapa bastante importante na elaboração de modelos preditivos (24, 25). A partir deste procedimento, podemos obter os valores dos parâmetros para os quais o modelo melhor representa os dados observados. Após “informar” o modelo com essas observações, podemos inferir cenários que não foram observados, obviamente dentro das limitações epistemológicas do modelo (hipóteses e simplificações) e das incertezas inerentes às observações (irredutíveis e aleatórias). Em nosso estudo, utilizamos a abordagem Bayesiana para Calibração por meio de um método de Monte Carlo Transicional via Cadeias de Markov denominado *Cascading Adaptive Transitional Metropolis in Parallel* (26), denotado por CATMIP de agora em diante. Em suma, como a tradicional família de métodos de Monte Carlo via Cadeias de Markov, o CATMIP fornece as distribuições dos parâmetros do modelo e os correspondentes valores mais prováveis. Dessa forma, em contraste com calibrações determinísticas (como os métodos clássicos de Mínimos Quadrados) que informam apenas um valor do parâmetro ao final do procedimento, obtemos também conhecimentos adicionais sobre a probabilidade do valor do parâmetro, incorporando informações sobre sua incerteza.

Em nosso estudo apenas alguns parâmetros foram calibrados com base nos dados observados. Duas razões motivaram essa escolha: (i) existência na literatura de valores de parâmetros já mensurados com base em dados; (ii) dificuldades de não-identificabilidade prática de parâmetros (27, 28). Sobre este último ponto, a principal dificuldade de identificação é a existência de muitos parâmetros no modelo enquanto poucos dados são disponíveis para a calibração. Dessa forma, a calibração não é capaz de obter um resultado único, inviabilizando a identificação dos valores mais prováveis dos parâmetros, assim como sua incerteza associada. Nesse contexto, utilizamos informações disponibilizadas na literatura sobre valores de alguns parâmetros presentes no modelo. A Tabela 3 resume os resultados obtidos na calibração e apresenta quais valores foram retirados da literatura. É importante observar que a taxa de diagnóstico (ε) é atualmente um problema no Brasil, e aqui postulamos a hipótese de que os sintomáticos que serão diagnosticados apresentam sintomas severos e, neste caso, o diagnóstico é feito em torno de 3 dias. O número de reprodução basal foi calculado por meio das realizações do CATMIP para as distribuições de probabilidade *a posteriori* obtidas para os parâmetros.

Parâmetro	Valor mais provável (BR)	Valor mais provável (RJ)	Distribuição a priori	Fonte do dado
$\beta = \mu$	5.965935×10^{-9}	4.658646×10^{-8}	$\mathcal{U}(0, 1 \times 10^{-5})$	CATMIP
σ	1/5	1/5	–	Baseado em (29)
ρ	0.85	0.85	–	Baseado em (30)
ε_I	1/3	1/3	–	Hipótese
$\gamma_A, \gamma_I, \gamma_P$	1/14	1/14	–	Baseado em (31)
d_I	1.356770×10^{-2}	5.549912×10^{-4}	$\mathcal{U}(0, 0.1)$	CATMIP
d_P	4.1681711×10^{-3}	1.315661×10^{-2}	$\mathcal{U}(0, 0.1)$	CATMIP
ω	1.970400×10^{-2}	1.438746×10^{-2}	$\mathcal{U}(0, 1)$	CATMIP
\mathcal{R}_0	4.093360	2.830033	–	CATMIP (pós-processamento)
σ_C (desvio-padrão para casos confirmados)	2040	148	$\mathcal{U}(1, 10000)$	CATMIP
σ_D (desvio-padrão para total de óbitos)	81	22	$\mathcal{U}(1, 10000)$	CATMIP

Tabela 3. Parâmetros do modelo: valores mais prováveis e dados considerados para o Estado do Rio de Janeiro e Brasil. As distribuições *a priori* utilizadas também são disponibilizadas.

É importante informar que, para realizar as calibrações, utilizamos como dados observados séries temporais dos números acumulados de casos confirmados e de óbitos. Para tanto, consideramos que, a partir do modelo SEAIRPD-Q, a quantidade acumulada de casos confirmados pode ser computada como

$$C(t) := \int_{t_0}^t \varepsilon_I I(t) dt, \quad [1]$$

e a quantidade total de óbitos calculada como

$$D(t) := \int_{t_0}^t [d_I I(t) + d_P P(t)] dt, \quad [2]$$

sendo t_0 o dia inicial considerado em ambas as séries temporais. Note que, dessa forma, podemos estimar a quantidade de casos confirmados e óbitos para um dia t . Para determinar qual seria o dia t_0 selecionamos o momento em que havia mais de 5 casos confirmados, o que ocorreu nos dias 05/03/2020 e 10/03/2020 para o Brasil (BR) e o Estado do Rio de Janeiro (RJ), respectivamente. Iremos nos referir a $t_0 = 0$ e t como dias de simulação. Os dados utilizados foram retirados de (8) para o Brasil e de (32) para o Estado do Rio de Janeiro. Para o BR, foram considerados 63 dias de simulação na calibração, iniciando em 05/03/2020 e encerrando em 06/05/2020. Para o RJ, 53 dias de simulação foram utilizados, iniciando em 10/03/2020 e finalizando em 01/05/2020.

Estratégias de relaxamentos abrupto, gradual e manutenção do distanciamento social vigente. A calibração reflete o estado da política vigente de distanciamento social refletido nos dados utilizados e correspondente janela temporal. Para realizar as projeções, considerando que a política vigente se mantém sem alterações, basta projetar as simulações do modelo em uma janela temporal mais ampla, sem quaisquer alterações no modelo. No entanto, temos como principal objetivo avaliar diferentes medidas de relaxamento de distanciamento social, e isso requer alterações no modelo para incorporar a representação dessas medidas. Para tanto, propomos alterações para o parâmetro ω , que representa a taxa de remoção para quarentena/distanciamento social. Para modelarmos a aplicação de medidas de relaxamento do distanciamento social, adotaremos ω como uma função de decaimento exponencial formulada como:

$$\omega(t; t_d, t_{1/2}) := \omega_c e^{-\lambda(t-t_d)} \quad [3]$$

onde

$$\lambda := \frac{\ln 2}{t_{1/2}} \quad [4]$$

sendo ω_c , t_d e $t_{1/2}$ o valor de ω calibrado, o dia do início do relaxamento e o tempo de meia-vida do decaimento exponencial, respectivamente. Dessa forma, é possível modelar medidas de relaxamento aplicadas à taxa de remoção devido ao distanciamento social por meio da utilização de valores de tempo de meia-vida correspondentes aos cenários. O tempo de meia-vida é a quantidade de dias após t_d até que a taxa de remoção devido ao distanciamento social seja reduzida à metade de seu valor inicial (no caso, metade do valor obtido na calibração). Portanto, um tempo de meia-vida muito curto simboliza um decaimento muito rápido de ω , enquanto um tempo de meia-vida longo resulta em uma diminuição lenta do valor de ω . Logo, considerando uma situação em que o pico da epidemia (em relação à população de positivamente diagnosticados) tenha passado e que o provável controle da doença é verificado, i.e., tem-se $\mathcal{R}(t) < 1$, analisamos 3 cenários de interesse com o início do relaxamento do distanciamento social em $t_d = 100$:

1. Relaxamento abrupto do distanciamento social: com um tempo de meia-vida de $t_{1/2} = 0.1$ dias;
2. Relaxamento gradual do distanciamento social: com um tempo de meia-vida de $t_{1/2} = 15$ dias;
3. Manutenção da estratégia vigente de distanciamento social: neste caso, mantemos o valor de ω calibrado adotando $t_{1/2}$ muito grande de forma que $\lambda \rightarrow 0$ e portanto $\omega \rightarrow \omega_c$.


Nas Figuras 6 e 7 apresentamos resultados dos cenários de interesse para o BR e para o RJ, respectivamente. É evidente que, para ambos BR e RJ, um relaxamento abrupto – mesmo em uma situação de aparente controle – pode ocasionar um agravamento considerável no possível resultado a longo prazo da epidemia, aumentando o número total de casos confirmados e óbitos. Além disso, a duração da crise tem um notável prolongamento, i.e., o momento em que o número de casos confirmados diários e novos óbitos se reduzem a zero ou estejam próximos dessa condição. Por sua vez, no mesmo contexto de uma situação epidêmica controlada, um relaxamento gradual do distanciamento social pode resultar em um pequeno agravamento em termos de quantidades totais de casos confirmados e óbitos, com um ligeiro aumento na duração da crise. No entanto, as distribuições comparando os cenários de distanciamento social vigente com o relaxamento gradual são similares em relação a faixa de valores e intervalos de credibilidade, o que sugere que o relaxamento gradual poderia ser aplicado no contexto analisado.

É importante ressaltar os impactos do relaxamento do distanciamento social sobre o controle da epidemia. Adotar esse tipo de medida afeta diretamente a evolução do número de reprodução efetivo ($\mathcal{R}(t)$) da doença. As Figuras 8a e 8b mostram o comportamento predito de $\mathcal{R}(t)$ para o BR e o RJ, respectivamente. Para ambas as localidades, a aplicação do relaxamento de distanciamento social implica em uma estagnação ou diminuição muito mais lenta de $\mathcal{R}(t)$, a partir do momento de implementação das medidas. Por já se encontrar em situação controlada ($\mathcal{R}(t) < 1$), a consequência associada a uma diminuição da taxa em que $\mathcal{R}(t)$ decresce é o longo atraso no tempo para a erradicação da doença, não alcançado até o tempo final das simulações realizadas.


Impacto da escolha do momento de aplicação relaxamento de distanciamento social. A partir dos resultados discutidos sobre os cenários de medidas de relaxamento do distanciamento social, fica evidente a relevância do grau de relaxamento adotado na medida. Porém, os estudos mostrados anteriormente foram realizados em situação de controle epidemiológico, isto é, com $\mathcal{R}(t) < 1$. Um questionamento que ocorre imediatamente é: quais os impactos da adoção de medidas de relaxamento de distanciamento social quando não há indicativos de controle epidemiológico ($\mathcal{R}(t) > 1$)?

Na prática, o valor de $\mathcal{R}(t)$ pode ser difícil de mensurar, quando não impossível, especialmente em localidades onde há sub-notificação considerável. Para ilustrar qualitativamente o impacto que medidas de relaxamento podem ocasionar quando não há controle epidemiológico comprovado, simularemos os mesmos cenários da sub-seção anterior, porém com as medidas sendo aplicadas nos dias de simulação 61 e 60 para BR e RJ (antes dos picos de positivamente diagnosticados), respectivamente. Os resultados para o BR e RJ são exibidos nas Figuras 9 e 10, respectivamente.


Analisando qualitativamente os resultados, é notável que adoção de ambas as medidas de relaxamento do distanciamento social, na ausência de evidências de controle epidemiológico, ocasiona agravamento substancial no crescimento do número de casos confirmados e óbitos. Além disso, a aplicação de relaxamento gradual pode levar a um tempo de crise maior quando comparado com o relaxamento abrupto. Isso fica evidente pelo estágio de crescimento dos casos confirmados e óbitos comparando-se os resultados apresentados nas Figuras 9a e 9b (ou 10a e 10b), com a Figura 9b (ou 10b), sugerindo um direcionamento para um platô. Por outro lado, a Figura 9a (ou 10a) apresenta tendências de aumento dos números de casos confirmados e óbitos sem indicativo de direcionamento a um platô.




(a) Estimativas dos valores médios de casos confirmados.



(b) Estimativas dos valores médios de total de óbitos.



(c) Distribuição da estimativa de casos confirmados no último dia de simulação.



(d) Distribuição da estimativa de total de óbitos no último dia de simulação.

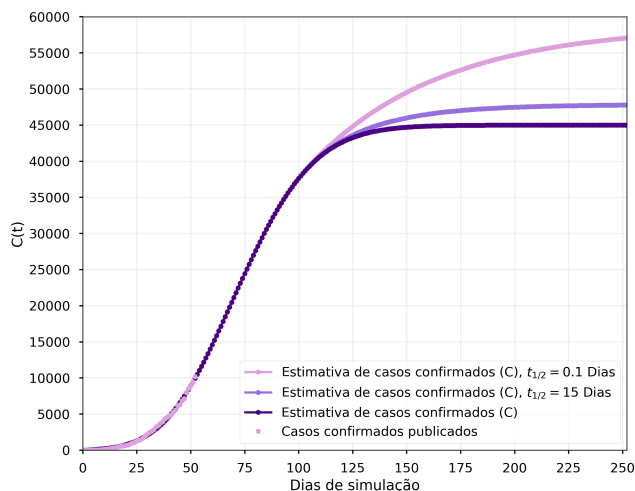
Figura 6. Resultados para o BR dos cenários de interesse. O caso "original" refere-se ao cenário onde se mantém a estratégia de distanciamento social vigente.

Para entendermos melhor esses resultados, temos que analisá-los conjuntamente com a Figura 11. No cenário de relaxamento abrupto do distanciamento social, $\mathcal{R}(t) > 1$ ocorre por uma maior quantidade de dias quando comparado com o relaxamento gradual, que com poucos dias alcança $\mathcal{R}(t) < 1$ e se estabiliza. Devido ao relaxamento abrupto continuar por mais dias, em uma situação sem controle epidemiológico, a doença se espalha, aumentando o número de infectados e diminuindo o número de indivíduos suscetíveis. Dessa forma, no relaxamento abrupto, a doença detém um crescimento no número de indivíduos infectados, aumentando da mesma maneira a parcela imunizada da população com o tempo, ocasionando eventualmente uma desaceleração na propagação da epidemia. É importante ressaltar que isso ocorre à custa de números de casos confirmados e óbitos 10 vezes maiores para o relaxamento abrupto quando comparado ao gradual.


Independentemente do cenário, é evidente a importância do momento em que se inicia uma medida de relaxamento do distanciamento social. Quando se compara qualitativamente os resultados de medidas de relaxamento em situação de controle epidemiológico com aqueles obtidos na ausência desse controle, mesmo para uma estratégia de relaxamento gradual, os números são catastróficos. É importante que essas medidas sejam analisadas e planejadas apenas quando se há evidências de controle epidemiológico, seja por meio de intervenções farmacológicas ou não.

Comentários finais


Por meio de simulações de um modelo compartimental original, investigamos cenários de estratégias de manutenção e relaxamento de distanciamento social no Brasil e, em particular, no Estado do Rio de Janeiro. Esses cenários foram analisados tanto em situação de controle epidemiológico quanto na ausência desse controle. No cenário em que há controle epidemiológico, medidas de relaxamento de distanciamento social conduzidas de maneira abrupta podem levar a um aumento nos números de casos confirmados e óbitos quando comparados com a estratégia vigente, além de um prolongamento no tempo necessário




(a) Estimativas dos valores médios de casos confirmados.



(b) Estimativas dos valores médios de total de óbitos.



(c) Distribuição da estimativa de casos confirmados no último dia de simulação.



(d) Distribuição da estimativa de total de óbitos no último dia de simulação.

Figura 7. Resultados para o RJ dos cenários de interesse. O caso "original" refere-se ao cenário onde se mantém a estratégia de distanciamento social vigente.


para erradicação da epidemia. Por outro lado, uma abordagem de relaxamento gradual, no cenário de controle epidemiológico, sugere ligeira diferença em relação à abordagem vigente, tanto para números de casos confirmados e óbitos quanto para o tempo de erradicação da epidemia. Portanto, aferido o controle epidemiológico, medidas de relaxamento gradual são viáveis, enquanto que as de relaxamento abrupto podem não ser favoráveis. Para a situação em que não há evidência de controle epidemiológico, ambas as medidas de relaxamento do distanciamento social analisadas se mostraram desfavoráveis, com aumento significativo nos números de casos confirmados e óbitos quando comparados com a estratégia de distanciamento social vigente.

O modelo original proposto (SEAIRPD-Q), na forma que foi apresentada nesta nota técnica, não considera a possibilidade de reinfecção, tema ainda inconclusivo na literatura, o que o impede de prever uma segunda onda da doença, por exemplo. O modelo também não considera fatores sociais e demográficos, e efeitos migratórios entre localidades. Um outro fator importante, não incluído na presente modelagem, se refere à existência de sub-notificação. Estes são temas a serem investigados futuramente.


Cabe também ressaltar que os modelos compartimentais locais podem não ser adequados para representar populações em regiões que tenham elevada heterogeneidade demográfica, como localidades de territórios extensos. No entanto, para os fins das análises qualitativas desse trabalho essa limitação não compromete as características de interesse analisadas e as conclusões.

Aspectos que abordamos nesta nota técnica são apresentados com maior profundidade e discussão em (33). Outras questões não tratadas aqui, como o impacto das incertezas dos parâmetros do modelo sobre a dinâmica da infecção, também estão presentes em (33).

AGRADECIMENTOS. ACMR, LA e JVOs agradecem ao suporte provido pelo CNPq a partir dos projetos 132591/2014-6, 301327/2020-3 e 166171/2018-2. Essa pesquisa foi parcialmente financiada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), código 001.

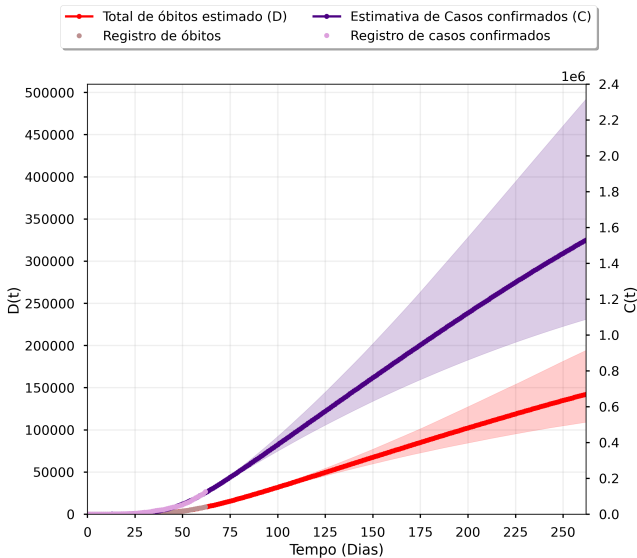


(a) Brasil.

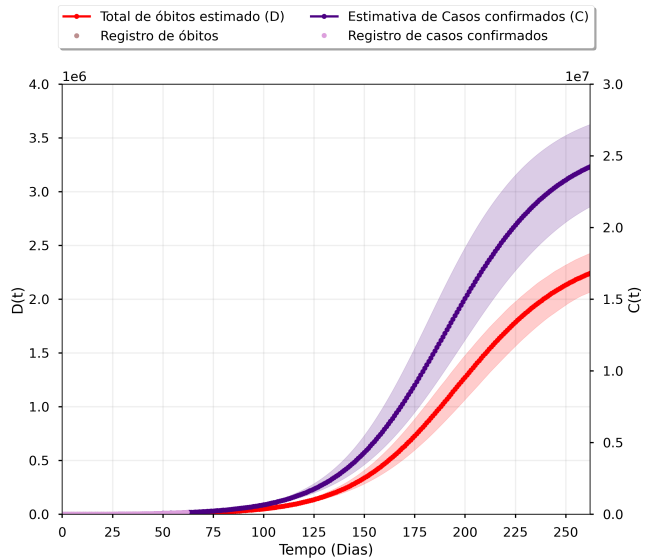


(b) Estado do Rio de Janeiro.

Figura 8. Evolução temporal comparativa de $\mathcal{R}(t)$ considerando os cenários de relaxamento do distanciamento social. As linhas tracejadas em vermelho delimitam o intervalo de credibilidade (95%) de dias que $\mathcal{R}(t) < 1$ pode ocorrer. As regiões sombreadas ao redor das curvas de $\mathcal{R}(t)$ representam intervalos de credibilidade de 95%.



(a) $t_{1/2} = 15$.



(b) $t_{1/2} = 0.1$.

Figura 9. Projeção de acumulado de casos confirmados e óbitos para o BR. As regiões sombreadas ao redor das curvas representam intervalos de credibilidade de 95%.




Figura 10. Projeção de acumulado de casos confirmados e óbitos para o RJ. As regiões sombreadas ao redor das curvas representam intervalos de credibilidade de 95%.

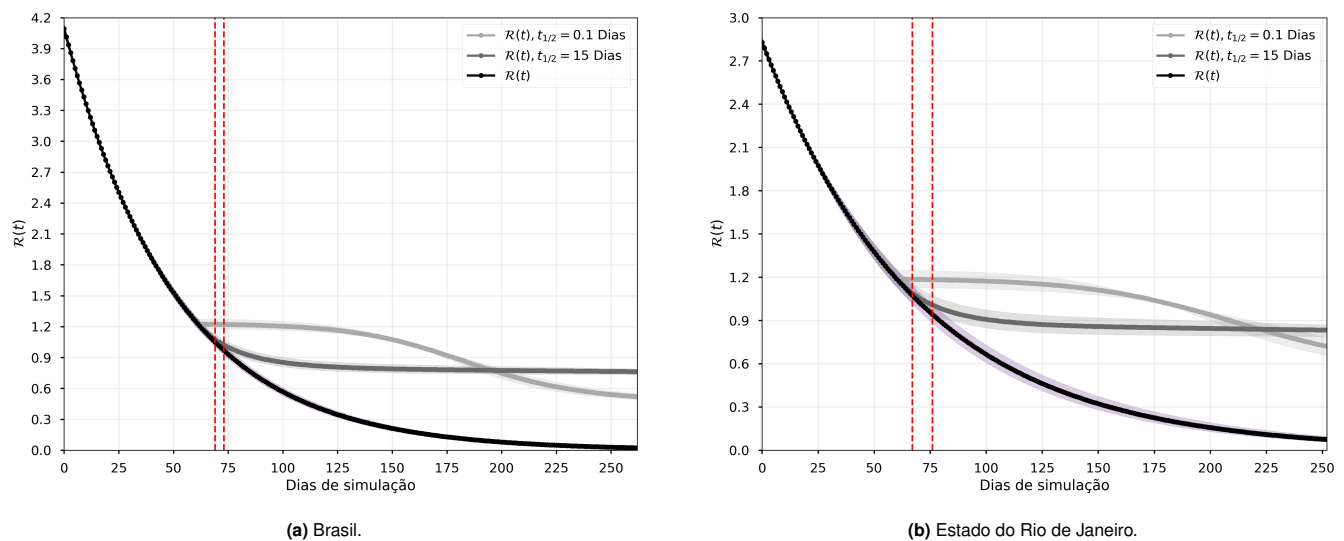









Figura 11. Evolução temporal comparativa de $\mathcal{R}(t)$ considerando os cenários de relaxamento do distanciamento social aplicado antes da ocorrência de $\mathcal{R}(t) < 1$. As linhas tracejadas em vermelho delimitam o intervalo de credibilidade (95%) de dias que $\mathcal{R}(t) < 1$ pode ocorrer. As regiões sombreadas ao redor das curvas de $\mathcal{R}(t)$ representam intervalos de credibilidade de 95%.

REFERÊNCIAS BIBLIOGRÁFICAS

1. WHO, WHO Timeline - COVID-19 (<https://www.who.int/news-room/detail/27-04-2020-who-timeline—covid-19>) (2020).
2. B Tang, et al., Estimation of the transmission risk of the 2019-ncov and its implication for public health interventions. *J. clinical medicine* **9**, 462 (2020).
3. J Jia, et al., Modeling the control of COVID-19: impact of policy interventions and meteorological factors. *Electron. J. Differ. Equations* **2020**, 1–24 (2020).
4. JR Koo, et al., Interventions to mitigate early spread of SARS-CoV-2 in Singapore: a modelling study. *The Lancet Infect. Dis.* (2020).
5. N Ferguson, et al., Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand. *Imp. Coll. Rep.* (2020).
6. S Flaxman, et al., Report 13: Estimating the number of infections and the impact of non-pharmaceutical interventions on COVID-19 in 11 European countries. *Imp. Coll. Rep.* (2020).
7. Center for Systems Science and Engineering at Johns Hopkins University, COVID-19 Data Repository (<https://github.com/CSSEGISandData/COVID-19>) (Acessado em 23 de Maio de 2020).
8. Ministério da Saúde brasileiro, Painel geral – COVID-19 (<https://covid.saude.gov.br/>) (Acessado em 23 de Maio de 2020).
9. COVID-19 Brasil, Análise de sub-notificação (<https://ciis.fmrp.usp.br/covid19/analise-subnotificacao/>) (Acessado em 23 de Maio de 2020).
10. R Li, et al., Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (SARS-CoV2). *Science* (2020).
11. M Gatto, et al., Spread and dynamics of the COVID-19 epidemic in Italy: Effects of emergency containment measures. *Proc. Natl. Acad. Sci.* **117**, 10484–10491 (2020).
12. BF Maier, D Brockmann, Effective containment explains subexponential growth in recent confirmed COVID-19 cases in China. *Science* (2020).
13. K Prem, et al., The effect of control strategies to reduce social mixing on outcomes of the COVID-19 epidemic in Wuhan, China: a modelling study. *The Lancet Public Heal.* (2020).
14. S Feng, et al., Rational use of face masks in the COVID-19 pandemic. *The Lancet Respir. Medicine* **8**, 434–436 (2020).
15. T Greenhalgh, MB Schmid, T Czypionka, D Bassler, L Gruer, Face masks for the public during the COVID-19 crisis. *Bmj* **369** (2020).
16. Centro de Pesquisas Epidemiológicas da Universidade Federal de Pelotas, EPICOV19 (<http://epidemiologia.ufpel.org.br/uploads/downloads/276e0cfc2783c68f57b70920fd2acfb.pdf>) (2020).
17. S Zhang, et al., Estimation of the reproductive number of novel coronavirus (COVID-19) and the probable outbreak size on the Diamond Princess cruise ship: A data-driven analysis. *Int. J. Infect. Dis.*, 201–204 (2020).
18. LJ Allen, F Brauer, P Van den Driessche, J Wu, *Mathematical epidemiology*. (Springer) Vol. 1945, (2008).
19. MJ Keeling, P Rohani, *Modeling infectious diseases in humans and animals*. (Princeton University Press), (2011).
20. VP Klóh, et al., The virus and socioeconomic inequality: An agent-based model to simulate and assess the impact of interventions to reduce the spread of COVID-19 in Rio de Janeiro, Brazil/O vírus e a desigualdade socioeconômica: um modelo baseado em agentes para simular e avaliar o impacto de intervenções para reduzir a disseminação do COVID-19 no Rio de Janeiro, Brasil. *Braz. J. Heal. Rev.* **3**, 3647–3673 (2020).
21. P Van den Driessche, J Watmough, Reproduction numbers and sub-threshold endemic equilibria for compartmental models of disease transmission. *Math. Biosci.* **180**, 29–48 (2002).
22. P van den Driessche, Reproduction numbers of infectious disease models. *Infect. Dis. Model.* **2**, 288–303 (2017).
23. O Diekmann, JAP Heesterbeek, MG Roberts, The construction of next-generation matrices for compartmental epidemic models. *J. R. Soc. Interface* **7**, 873–885 (2010).
24. JT Oden, R Moser, O Ghattas, Computer predictions with quantified uncertainty, part I. *SIAM News* **43** (2010).
25. JT Oden, R Moser, O Ghattas, Computer predictions with quantified uncertainty, part II. *SIAM News* **43** (2010).
26. SE Minson, M Simons, JL Beck, Bayesian inversion for finite fault earthquake source models theory and algorithm. *Geophys. J. Int.* **194**, 1701–1726 (2013).
27. A Raue, et al., Structural and practical identifiability analysis of partially observed dynamical models by exploiting the profile likelihood. *Bioinformatics* **25**, 1923–1929 (2009).
28. G Chowell, Fitting dynamic models to epidemic outbreaks with quantified uncertainty: a primer for parameter uncertainty, identifiability, and forecasts. *Infect. Dis. Model.* **2**, 379–398 (2017).
29. SA Lauer, et al., The incubation period of coronavirus disease 2019 (COVID-19) from publicly reported confirmed cases: estimation and application. *Annals internal medicine* **172**, 577–582 (2020).
30. K Mizumoto, K Kagaya, A Zarebski, G Chowell, Estimating the asymptomatic proportion of coronavirus disease 2019 (COVID-19) cases on board the Diamond Princess cruise ship, Yokohama, Japan, 2020. *Eurosurveillance* **25**, 2000180 (2020).
31. F Pan, et al., Time course of lung changes on chest CT during recovery from 2019 novel coronavirus (COVID-19) pneumonia. *Radiology*, 200370 (2020).
32. W Cota, Monitoring the number of COVID-19 cases and deaths in Brazil at municipal and federative units level. *SciELOPreprints:362* (2020).
33. DT Volpatto, et al., Spreading of COVID-19 in Brazil: Impacts and uncertainties in social distancing strategies. *A ser submetido* (2020).

Assessing social distancing release strategies in Brazil and Rio de Janeiro state

Diego T. Volpatto ^{a,*}, Anna Claudia M. Resende ^a, Lucas dos Anjos ^a, João V. O. Silva ^a, Claudia M. Dias ^b, Regina C. Almeida ^a e Sandra M. C. Malta ^a

^aLNCC, Laboratório Nacional de Computação Científica, Petrópolis, RJ, Brasil; ^bUFRRJ, Universidade Federal Rural do Rio de Janeiro, Nova Iguaçu, RJ, Brasil

Technical report written on May 23, 2020

In this technical report, we discuss some measures to release social distancing and their impacts in the epidemiological sense in order to assess the effects on the projections of the COVID-19 epidemic in Brazil and, in particular, in the state of Rio de Janeiro. The analysis of relaxation scenarios for social distancing is a topic of great relevance to aid the estimation of the most appropriate moment for the return to normality in daily life. In this context, we discuss the importance - and possible consequences - of relaxing social distancing at an appropriate time. The results suggest that the adoption of gradual release policies of social distancing is feasible when epidemiological control is assured. On the other hand, in the absence of verification of epidemiological control, both gradual and abrupt release strategies generate a substantial increase in the number of confirmed cases and deaths, in addition to evidence of a considerable increase in the time required to eradicate the disease. Therefore, in the scenario where epidemiological control is not guaranteed, social distancing release policies analyzed in this research are not recommended.

Social Distancing | COVID-19 | SARS-CoV-2 | Compartmental Models