

Projeção de internações em terapia intensiva pela COVID-19 no Distrito Federal, Brasil: uma análise do impacto das medidas de distanciamento social

doi: 10.1590/S1679-49742020000500022

Projection of COVID-19 intensive care hospitalizations in the Federal District, Brazil: an analysis of the impact of social distancing measures

Proyección de hospitalizaciones en cuidados intensivos por COVID-19 en el Distrito Federal, Brasil: un análisis del impacto de las medidas de distanciamiento social

Ivan Zimmermann¹ –  orcid.org/0000-0001-7757-7519

Mauro Sanchez¹ –  orcid.org/0000-0002-0472-1804

Jonas Brant¹ –  orcid.org/0000-0003-2248-9102

Domingos Alves² –  orcid.org/0000-0002-0800-5872

¹Universidade de Brasília, Faculdade de Ciências da Saúde, Brasília, DF, Brasil

²Universidade de São Paulo, Faculdade de Medicina de Ribeirão Preto, Ribeirão Preto, SP, Brasil

Resumo

Objetivo: Construir cenários e analisar o impacto das políticas de distanciamento social na propagação da COVID-19 e a necessidade de leitos de unidades de terapia intensiva (UTI). **Métodos:** Sobre modelo compartimental de transição dinâmica e simulações de Monte Carlo, construíram-se três cenários de propagação conforme o nível de adesão às medidas de distanciamento social no Distrito Federal, Brasil. Os valores dos parâmetros do modelo fundamentaram-se em fontes oficiais, bases com indexação bibliográfica e repositórios públicos de dados. **Resultados:** O cenário favorável, com manutenção constante de 58% de adesão ao distanciamento social, estimou pico de 189 (intervalo interquartil [IIQ]: 57 a 394) internações-UTI em 7/3/2021. A ausência do distanciamento implicaria grave cenário, com pico de 6.214 (IIQ: 4.618 a 8.415) internações-UTI já na data provável de 14/7/2020. **Conclusão:** as projeções indicam alto impacto das medidas de distanciamento social e reforçam a aplicabilidade de indicadores públicos no monitoramento da COVID-19.

Palavras-chave: Infecções por Coronavirus; Unidades de Terapia Intensiva; Ocupação de Leitos; Avaliação em Saúde; Política Pública.

Endereço para correspondência

Ivan Zimmermann – Universidade de Brasília, Faculdade de Ciências da Saúde, Departamento de Saúde Coletiva, Brasília, DF, Brasil. CEP: 70910-900
E-mail: ivanzricardo@gmail.com

Introdução

A COVID-19, doença decorrente da infecção pelo vírus Sars-CoV-2, entre outras manifestações clínicas, pode incluir a síndrome respiratória aguda grave (SARS).¹ O primeiro caso no Brasil foi confirmado no dia 25/2/2020; em 3/5/2020, o país já contava, oficialmente, mais de 100 mil casos e 7 mil óbitos.² Dado seu amplo alcance e rápida propagação, seu potencial de levar a rede hospitalar ao colapso, sobretudo à disponibilidade insuficiente de leitos em unidades de terapia intensiva (UTI), a COVID-19 é considerada uma condição muito grave para a Saúde Pública.¹

Em cenários com limitação temporal na disponibilidade de dados, é de grande valor a construção de modelos e contrafactuais para identificar tendências e projeções dos possíveis impactos de uma determinada política pública.

Embora existam relatos de experiências com tratamentos e iniciativas para a obtenção de uma vacina, até o momento desta publicação, não havia comprovação robusta de eficácia de intervenções farmacológicas na prevenção ou tratamento dessa condição clínica.³ A ampla testagem, a proteção de profissionais (serviços de saúde e serviços essenciais), o isolamento de indivíduos infectados e a adoção de intervenções não farmacológicas, como as políticas públicas de distanciamento social, apresentam-se como a opção mais factível de abordagem da COVID-19.⁴ No dia 11/3/2020, com vigência em todo o Distrito Federal do Brasil, foram decretadas as primeiras medidas locais de distanciamento social diante do risco da infecção pelo novo coronavírus, incluindo a suspensão de eventos com público superior a 100 pessoas e as atividades educacionais em todas as escolas, universidades e faculdades.⁵ Adicionalmente, bares e restaurantes deveriam garantir a distância mínima de dois metros entre as mesas. Na data de 21/4/2020, além das medidas já aplicadas, o governo do Distrito Federal passou a adotar a testagem populacional de indivíduos sintomáticos, ampliando postos de coleta e triagem fora das unidades de saúde, exclusivamente para essas pessoas.

Com o intuito de monitorar e orientar as decisões de políticas públicas voltadas à COVID-19, uma série

de iniciativas e redes têm unido esforços e disponibilizado ferramentas de predição de casos, projeção de necessidade de leitos e de equipamentos hospitalares.⁶⁻⁸ Nesse aspecto, a análise de dados sobre políticas públicas, no que diz respeito à avaliação de seu impacto, é um campo de possíveis inferências, para as quais são indispensáveis dados robustos. Em cenários com limitação temporal na disponibilidade de dados, é de grande valor a construção de modelos e contrafactuais (cenários possíveis, não necessariamente observados) para identificar tendências e projeções dos possíveis impactos de uma determinada política pública.⁹

Tomando por base o contexto da ocorrência de casos de COVID-19 na população do Distrito Federal, o objetivo deste estudo foi construir cenários para analisar o impacto das políticas de distanciamento social na propagação da COVID-19 e a necessidade de leitos em UTIs, com o auxílio de um modelo matemático e simulações de Monte Carlo.

Métodos

Tendo como referência os fundamentos e delineamentos de pesquisas no campo da avaliação de políticas públicas,⁹ trata-se de um estudo de caso, pautado em simulações. Após a coleta de dados e indicadores, foram construídos cenários de projeções e contrafactuais, relevantes para a análise do impacto das medidas de distanciamento social sobre a demanda por leitos de UTI no contexto observado.

Como caso desta análise, considera-se a conformação de todas as regiões administrativas integrantes do Distrito Federal, cuja população total é estimada em 3.223.048 habitantes para 2020, de acordo com projeções do Instituto Brasileiro de Geografia e Estatística (IBGE).¹⁰ No intuito de obter uma referência da capacidade hospitalar instalada, foi consultado o número de leitos de UTI-adulto cadastrados na região, segundo o banco de dados do Cadastro Nacional de Estabelecimentos de Saúde (CNES) disponível até o mês de junho de 2020. Complementarmente, visando contextualizar a adesão da população às medidas de distanciamento social recomendadas pelas políticas instituídas, foram consultados os dados públicos do 'índice de isolamento social' no Distrito Federal, referentes ao período de 1/3/2020 a 31/7/2020, disponibilizados pela empresa de tecnologia Inloco.¹¹ Tal indicador tem auxiliado iniciativas de monitoramento da propagação

da COVID-19, desenvolvidas por universidades públicas e instituições governamentais. Fazendo uso de dados de geolocalização de dispositivos telefônicos de uma parcela da população local – mediante autorização prévia –, é possível estimar, diariamente, o percentual dessa população que tem acatado as orientações públicas de isolamento social.¹¹

Estrutura do modelo

Para estimar a necessidade de leitos de UTI decorrente da propagação da doença, construiu-se um modelo matemático. Adotada a diretriz metodológica publicada pela Secretaria de Ciência, Tecnologia e Insumos Estratégicos do Ministério da Saúde¹² e os fundamentos práticos da modelagem de doenças infecciosas,¹³ decidiu-se pela concepção de um modelo compartimental de transição dinâmica. Neste modelo, derivado da clássica proposta do modelo SIR (sigla para ‘suscetíveis, infectados e recuperados’) proposto por Kermack e McKendrick, a transição entre os compartimentos (ou estados de saúde) é representada por um sistema de equações diferenciais dependentes, entre outros parâmetros, de número de infectados (I), coeficiente de transmissão (β), latência (α) e recuperação (γ).

Adotou-se, neste trabalho, uma estrutura de transições e compartimentos orientada por modelos disponibilizados previamente, por outros autores que também buscavam a projeção da demanda hospitalar,¹⁴⁻¹⁶ além do impacto de intervenções não farmacológicas – como o uso de máscaras – sobre a propagação comunitária da COVID-19.¹⁷ Nesta proposta, o modelo para a relação diária entre o número de indivíduos suscetíveis (S), expostos (E), infectados (I) e removidos (R) – SEIR – é representado na Figura 1.

Dentro do compartimento de infectados, são ainda consideradas as subdivisões dos indivíduos que não necessitam de hospitalização (I_1), aqueles que evoluem para a necessidade de hospitalização (I_2) e, por fim, os pacientes com quadro crítico (I_3) que evoluem para a necessidade de internação em UTI.

Principais premissas do modelo

a) Não é prevista a mudança do tamanho total da população (natalidade e mortalidade geral), exceto pela morte por COVID-19. Dado o curto horizonte temporal de análise, considerou-se que tal restrição

simplificaria o modelo, com pouco impacto nos resultados.

- b) Semelhantemente a abordagens prévias, baseadas em modelos SEIR da COVID-19,¹⁷ assume-se que os indivíduos hospitalizados não estejam efetivamente expostos à população geral e, portanto, não contribuam para o cálculo da força de infecção na comunidade.
- c) Não é prevista a possibilidade de reinfeção de um indivíduo recuperado, ainda que não existam evidências definitivas sobre o grau com que a imunidade adquirida, após a infecção de fato, proteja-o de reinfeção.¹⁸
- d) Não sendo objetivo da análise, o presente modelo desconsidera o potencial aumento da mortalidade devido à falta de leitos. É mister considerar que a letalidade observada no modelo possa estar subestimada em um cenário de indisponibilidade de leitos.
- e) As estimativas de contato efetivo assumem o pressuposto da mistura homogênea (*random mixing*),¹³ onde cada indivíduo infectado possa entrar em contato com um indivíduo suscetível de acordo com a mesma probabilidade média.

As equações completas e mais detalhes sobre o modelo estão disponíveis no Material Suplementar 1.

Cenários

No horizonte temporal de 1 ano, período considerado suficiente para abarcar tanto uma onda completa de infecções como a incerteza sobre a disponibilidade ou não de futuras intervenções específicas (vacinas e tratamentos), tomando-se como referencial a data inicial de 22/3/2020, dada a margem de dez dias entre o início das medidas de distanciamento social e o pico dos níveis de isolamento social obtido no Distrito Federal, foram construídos três cenários de propagação da COVID-19, visando analisar o impacto potencial da doença sobre a necessidade de atendimento hospitalar.

Cenário A – Perfil de propagação sem adesão às medidas de distanciamento social

Definição

Representa o contrafactual do que ocorreria se não fossem tomadas ou aderidas pela população as medidas de distanciamento social.

Para tanto, ao longo do modelo, não é inferida nenhuma redução do contato social, adotando-se a

estimativa média de isolamento social observada nos últimos dez dias antes do decreto local de 11/3/2020.

Assim, adota-se um valor constante para o coeficiente de transmissão (β) no modelo.

Cenário B – Perfil de propagação com manutenção da adesão ao distanciamento social

Definição

Representa o perfil de propagação da infecção e de necessidade de leitos com a manutenção do nível de isolamento social médio obtido nos primeiros dez dias após o pico de isolamento social.

Neste cenário, o modelo também adota um coeficiente de transmissão (β) constante.

Cenário C – Perfil de propagação com a dinâmica observada de queda do nível de distanciamento social

Definição

Representa a dinâmica de isolamento social observada no Distrito Federal e a possível projeção da necessidade de leitos com a manutenção dos últimos níveis médios de isolamento observados.

Neste contexto, buscando simular uma interrupção ou retorno das medidas de distanciamento, são também estimadas metas de isolamento populacional de acordo com a demanda por leitos de UTI.

Conforme observado nas definições apresentadas, não foi prevista a simulação completa de cenários com uma adesão ao distanciamento acima da média observada após a implementação das políticas de distanciamento. Apesar disso, ressalta-se que a análise de metas de isolamento prevista no Cenário C não teve tal restrição.

Valores dos parâmetros e incertezas

Com o intuito de aproximar o modelo de análise à realidade local e ao tamanho da população, tomou-se a estrutura etária do Distrito Federal para o ajuste dos indicadores esperados de letalidade e hospitalização para a região. A partir dos boletins oficiais da Secretaria de Estado de Saúde do Distrito Federal,¹⁹ foram levantados os números de casos por data de início de sintomas, internações em UTI e óbitos por COVID-19. Além das

estimativas de infecção e letalidade por faixa etária para o Distrito Federal (Material Suplementar 2), a série completa de internações em UTI, óbitos e percentual de isolamento social disponíveis para o período de análise (dados de 1/3/2020 a 31/7/2020) é apresentada no Material Suplementar 3. Além dos parâmetros citados, para cada cenário estimou-se a evolução diária do número de reprodução instantâneo (R_t)

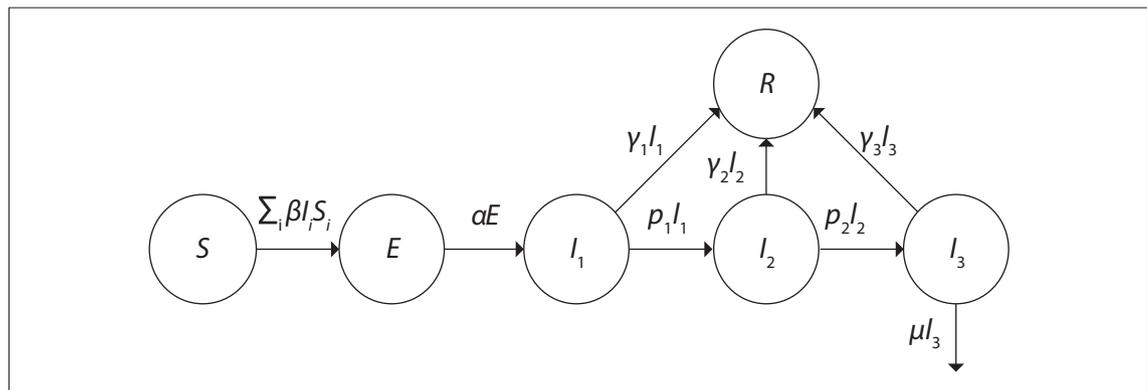
Na ausência de dados locais dos demais parâmetros, utilizando-se de uma adaptação da estrutura básica de busca com os termos (COVID-19 OR coronavirus) AND (*model OR modelling*), foram também consultadas publicações indexadas na base Pubmed (<http://www.ncbi.nlm.nih.gov/pubmed>), prévias de publicações na base MedRxiv (www.medrxiv.org) e repositórios públicos de parâmetros de modelagem, como a iniciativa da rede MIDAS (<http://midasnetwork.us/COVID-19>). A escolha das fontes de dados dos parâmetros disponíveis priorizou aquelas utilizadas em modelos validados por outras instituições de referência no tema, como os modelos do Imperial College London, buscando a comparabilidade do modelo aqui proposto. Os dados extraídos incluíram as estimativas pontuais e suas incertezas paramétricas (erros-padrão, intervalos de confiança ou distribuições de probabilidade). Os valores dos principais parâmetros considerados no modelo aqui proposto, acompanhados de sua incerteza paramétrica, descrição e fontes, são apresentados na Tabela 1.

Para considerar o impacto das incertezas paramétricas dos nove parâmetros descritos na Tabela 1, sobre os resultados do modelo, as análises foram conduzidas em uma abordagem estocástica (probabilística), fazendo-se uso de simulações de Monte Carlo, sendo conduzidos múltiplos sorteios em nível de valor esperado (2ª ordem).²⁰ Com base nas características das variáveis, foram ajustadas distribuições *a priori* de probabilidade para os parâmetros de tempo de incubação (dias), duração do quadro leve (dias), fração de indivíduos com quadro grave (%), tempo de internação em enfermaria (dias), fração de indivíduos que evoluem para internação em UTI (%), tempo de internação em UTI (dias), letalidade (%) e tempo do início dos sintomas até a morte (dias), conforme ilustrado no Material Suplementar 4. Na ausência de intervalos nas fontes de dados, considerou-se a reamostragem com reposição (*bootstrap*) para estimar a incerteza paramétrica (intervalos de confiança). Os resultados foram resumidos em medianas e amplitudes de cobertura das simulações (intervalo interquartil [IIQ] e intervalo de confiança [IC]).

Tabela 1 – Relação de valores, incertezas paramétricas, distribuições e fontes dos principais parâmetros do modelo de propagação da COVID-19 no Distrito Federal, Brasil

Parâmetro	Estimativa pontual	Limite inferior	Limite superior	Função de probabilidade	Descrição	Fonte
Incubação (dias)	5,10	4,50	5,80	Lognormal	Tempo de incubação	Sanches et al. ²⁶
Duração – leve (dias)	3,65	3,21	4,09	Gama	Duração do quadro até isolamento ou hospitalização	Linton et al. ²⁷
Quadro grave (%)	4,57	2,72	9,32	Beta	Proporção de infectados que terão quadro grave ou crítico (hospitalização)	Verity et al. ²⁸
Tempo de internação (dias)	8,00	6,00	10,00	Lognormal	Tempo médio de internação em enfermaria	Ferguson et al. ²⁹
Internação em UTI ^a (%)	46,30	44,31	48,06	Beta	Percentual de pacientes graves que necessitam de cuidados intensivos	Boletins Epidemiológicos ¹⁹
Tempo em UTI (dias)	9,00	6,00	13,00	Lognormal	Tempo médio de internação em UTI ^a	Grasselli et al. ³⁰
Letalidade (%)	0,576	0,315	1,140	Beta	Letalidade de infectados ajustada para a região	Verity et al. ²⁸
Tempo até a morte (dias)	17,80	16,02	19,58	Lognormal	Tempo médio do início dos sintomas até a morte	Verity et al. ²⁸
Mortalidade na UTI ^a (%)	27,23	12,85	47,81	Não se aplica	Probabilidade de morte em UTI ^a	Calibrado pela letalidade

a) UTI: unidade de terapia intensiva.



Fonte: Adaptado de Hill.¹⁵

Figura 1 – Representação da estrutura do modelo dinâmico compartimental adotado

Validação

Para a calibração do modelo, adotou-se a referência do cenário que reflete a propagação durante os níveis de distanciamento social observado (Cenário C). Foram registrados os valores da estatística da minimização da raiz quadrada do erro médio (RMSE) do número de óbitos preditos pelo modelo, observados na série temporal em análise. A adequação do número de simulações de MC foi avaliada com a inspeção visual da convergência dos principais parâmetros do modelo.

Todas as análises foram conduzidas com auxílio do *software* Microsoft Excel® e da linguagem de programação Visual Basic for Applications (VBA). O ajuste dos parâmetros de calibração foi realizado com

o método dos mínimos quadrados não linear, com apoio do algoritmo de otimização Generalized Reduced Gradient (GRG) não linear, implementado na função SOLVER. O modelo completo e seu histórico de versões estão disponíveis em um repositório público de dados.²¹

Resultados

Conforme as fontes oficiais consultadas, do período de 1/3/2020 até a data final de obtenção de dados para o modelo, 31/7/2020, havia-se confirmado 106.292 casos e 1.469 óbitos por COVID-19 no Distrito Federal.¹⁹ Ao se considerar a data do primeiro decreto local sobre as medidas de distanciamento, foi possível observar uma importante adesão inicial da população às medidas, dado

o aumento gradual do índice de isolamento social ao longo dos dias seguintes ao decreto, de uma média de 30,0% entre 2/3/2020 e 11/3/2020, para uma média de 57,4% entre 22/3/2020 e 30/4/2020 (Figura 2).

Considerando-se os registros de casos segundo a data de início dos sintomas, todos os cenários iniciaram as simulações na data de 22/3/2020, com uma estimativa média de 366 indivíduos infectados (I) e 732 expostos (E) – dada a existência de um número de reprodução instantâneo (Rt) mínimo de 2 sem o isolamento social. Com um RMSE de 83,5 nos valores preditos de óbitos, o valor do parâmetro τ foi estimado em 0,6979 na calibração do modelo. De acordo com o banco de dados do CNES, o Distrito Federal possuía, até o mês de junho, um total de 1.534 leitos de UTI-adulto, 378 deles públicos. A seguir, são apresentados os resultados de cada um dos cenários.

Cenário A – Perfil de propagação sem adesão às medidas de distanciamento social

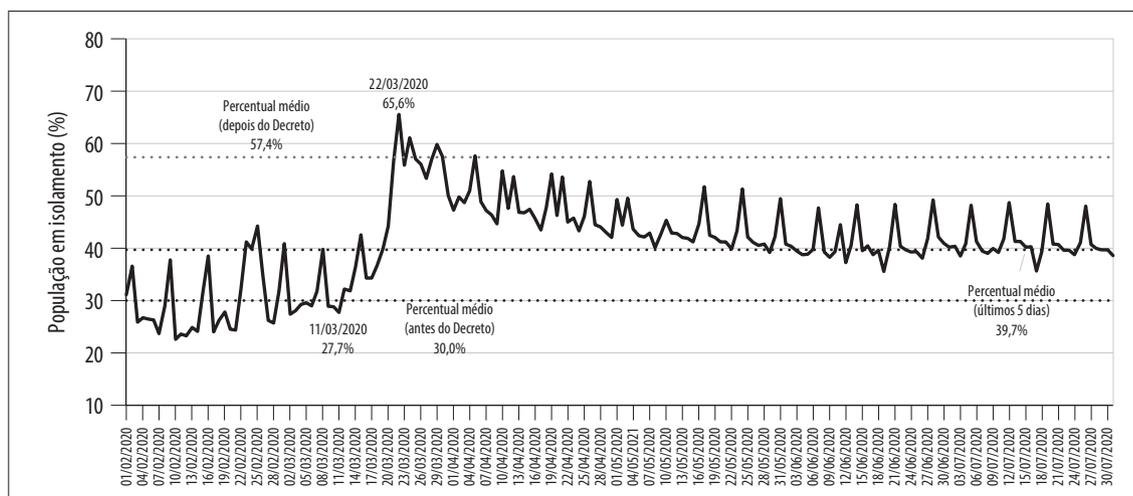
No primeiro cenário, o coeficiente de transmissão é calculado assumindo-se um nível de isolamento social de 30,0%, coerente com os valores médios observados até a data de 11/3/2020. Como ilustrado na Figura 3, dada a necessidade de hospitalização dos casos críticos, sem a adesão da população ao distanciamento social, haveria um pico de necessidade, com a mediana

das simulações, em 6.214 internações em UTI (IIQ: 4.618 a 8.415) na data provável de 14/7/2020 (IIQ: 9/7/2020 a 20/7/2020). No entanto, de acordo com os dados do CNES, o número total de leitos públicos de UTI cadastrados já teria sido ultrapassado na data de 17/5/2020 (IIQ: 12/5/2020 a 22/5/2020). Tal demanda, superior ao número de leitos públicos de UTI cadastrados, seria mantida por, ao menos, 125 dias (IIQ: 115 a 135).

No horizonte de um ano, seria provável um pico de 178.615 infecções ativas (IIQ: 153.820 a 203.955) na data de 1/7/2020 (IIQ: 26/6/2020 a 6/7/2020). Nesse ritmo, até a data de 31/3 do próximo ano (2021), seria prevista a infecção de até 73,2% da população do Distrito Federal (IIQ: 70,3 a 75,9%). Mesmo que fosse possível atender a todos os infectados, seria prevista a morte de 16.143 indivíduos (IIQ: 10.948 a 22.326) – letalidade esperada de 0,67% (IQR: 0,45 a 0,94%).

Cenário B – Perfil de propagação com manutenção da adesão ao distanciamento social

Considerando-se a hipótese de que se mantivesse a adesão no nível de isolamento social médio de 57,38%, obtido no período inicial das medidas de distanciamento, este cenário previa um pico de 189 internações em UTI (IIQ: 57 a 394) somente na data de 7/3/2021 (IIQ: 6/1/2021 a 31/1/2021) e, nesse contexto, seria factível



Fonte: dados da base pública da InLoco.¹¹

Figura 2 – Evolução do percentual de isolamento social de acordo com a data da implementação das medidas de enfrentamento à COVID-19 no Distrito Federal, Brasil

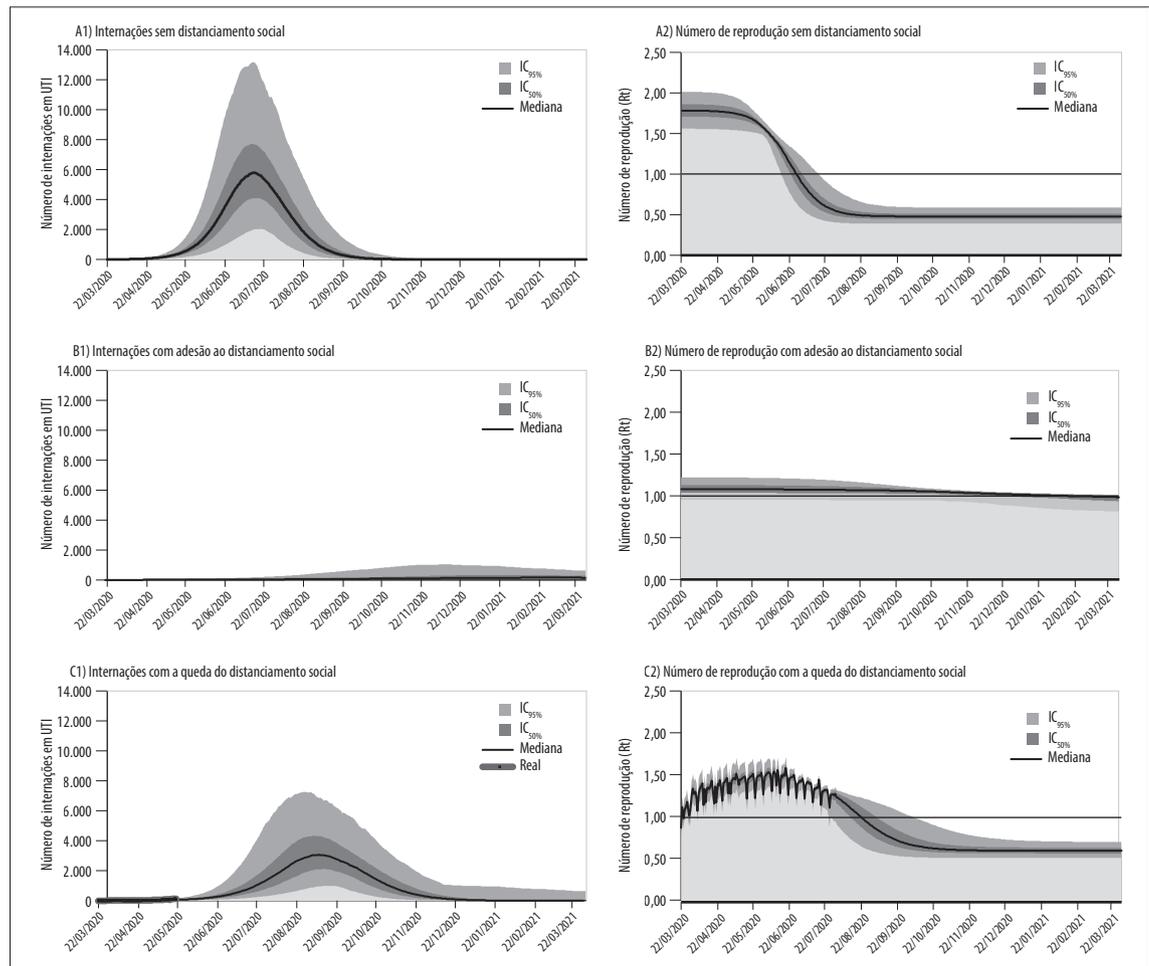


Figura 3 – Projeções da demanda por leitos de UTI pela COVID-19 e do número de reprodução instantâneo (R_t) nos cenários (A) Perfil de propagação sem adesão às medidas de distanciamento social, (B) Perfil de propagação com manutenção da adesão ao distanciamento social e (C) Perfil de propagação com a dinâmica observada de queda do nível de distanciamento social, no Distrito Federal, Brasil

atender a demanda com o número de leitos cadastrados no Distrito Federal.

Ao longo do período simulado de um ano, o número total de indivíduos infectados poderia atingir um pico de 5.269 infecções ativas (IIQ: 1.538 a 11.549). Até a data de 31/3/2021, o total de infecções acumuladas alcançaria apenas 7,6% da população do Distrito Federal (IIQ: 3,0 a 16,4%) e, com uma letalidade de 0,70% (IIQ: 0,47 a 0,94%), seriam esperados até 1.438 óbitos (IIQ: 583 a 3.234).

Cenário C – Perfil de propagação com a dinâmica observada de queda do nível de distanciamento social

Seguindo a proposta metodológica descrita para este cenário, o coeficiente de transmissão acompanhou a variação dinâmica do nível de isolamento registrado até a data de 31/7/2020. A partir de 1/8/2020, considerou-se a manutenção do nível de isolamento médio de 39,7%, conforme os valores registrados nos últimos cinco dias disponíveis.¹¹ Com isso, projetou-se que a queda observada do nível de distanciamento propiciaria um pico de até 3.460 internações em UTI (IIQ: 2.634 a 4.779) na data provável de 10/9/2020 (IIQ: 31/8/2020 a 22/9/2020) (Figura 3). Neste cenário, mesmo ao se elevar o nível de isolamento a uma média de 70% (valor próximo ao máximo obtido na data de 22/3/2020) a partir do dia 1/8/2020, ainda seria possível observar

um pico de 2.097 internações (IIQ: 1.245 a 3.312) na data de 19/8/2020 (IIQ: 16/8/2020 a 21/8/2020). Entretanto, a interrupção completa do distanciamento, retornando-se ao nível de isolamento de 30% observado antes da implementação das políticas de distanciamento, poderia provocar uma demanda com um pico de 4.812 internações em UTI (IIQ: 3.643 a 6.283) em 12/9/2020 (IIQ: 04/9/2020 a 21/9/2020).

Discussão

A partir de indicadores e dados públicos utilizados nesta análise, é possível identificar a adesão ao distanciamento social após a publicação do primeiro decreto de medidas de enfrentamento à COVID-19 no Distrito Federal. Igualmente, relacionando-se a evolução temporal do nível de isolamento com a consequente redução progressiva da propagação da doença (R_t), seria possível alcançar valores de referência para o controle de surtos e, ao mesmo tempo, postergar e reduzir o pico de internações em UTI para uma estimativa plausível diante da capacidade da rede assistencial local.

Diferentemente do cenário de manutenção do distanciamento social, todos os cenários de ausência de distanciamento social, seja pela não implementação das medidas (Cenário A), seja pela baixa adesão (Cenário C), mostram uma previsão compatível com o colapso da rede local devido à alta demanda por internações em UTI. Não obstante a incerteza sobre a data e a magnitude da demanda, as projeções alternativas do Cenário C, que busca incorporar os percentuais observados de isolamento social, apontaram picos de internações em meados de agosto e setembro deste ano. Tais projeções são consistentes com a situação de espera por leitos de UTI no Distrito Federal relatada no mês de agosto. Também coerentes com os achados de análise recente sobre outros estados brasileiros, realizada por pesquisadores do Imperial College London,²² não obstante reduções significativas da propagação de casos, os níveis de isolamento alcançados ainda perpetuariam um $R_t > 1$, indicando a manutenção do crescimento epidêmico da COVID-19 no Distrito Federal.

Apesar de esta análise ser restrita ao contexto do Distrito Federal, ela mostra a magnitude do efeito potencial do distanciamento sobre a necessidade de leitos, sendo improvável que tal relação, mesmo em

magnitude diferente, não se generalize para outros contextos. Os resultados são também consistentes com outras iniciativas de análise do distanciamento social,⁴ incluindo contextos nacionais, como a análise dos efeitos positivos do distanciamento social e da redução de fluxo intermunicipal no controle da COVID-19 na Bahia, pela Rede CoVida,⁶ cujos dados disponíveis sugerem, fortemente, que as medidas tomadas conseguiram suavizar a curva da epidemia naquele estado.

O modelo aqui adotado segue as linhas metodológicas compatíveis com a dinâmica populacional de infecções¹⁵ e foi construído sobre parâmetros locais, na medida do possível, incluindo o ajuste da taxa de infecção e letalidade para a estrutura etária do Distrito Federal. Ademais, buscou-se o uso transparente das evidências disponíveis e a condução robusta das incertezas paramétricas, mediante simulações de Monte Carlo.²⁰ Conforme demonstrado nesta análise, o acompanhamento de indicadores dinâmicos de isolamento e propagação da infecção, como a estimativa do R_t , acompanhados de sua incerteza, apresenta-se como uma estratégia eficiente e pragmática de monitoramento das políticas de enfrentamento da COVID-19.²³

Apesar de os modelos compartimentais em nível de valor esperado conseguirem representar o comportamento médio de epidemias nas populações, eles não são capazes de retratar histórias individuais.¹² Da mesma forma, a estimativa dos valores dinâmicos das taxas de contatos efetivos é discutida em abordagens variadas, na literatura, com diferentes impactos potenciais nos resultados, de acordo com o método de cálculo.²⁴ Embora considerados os ajustes relativos à estrutura etária local e calibração com base nos registros de internações disponíveis, não foram considerados outros fatores capazes de interferir nos cenários de projeção, a exemplo das comorbidades relacionadas à maior gravidade da progressão da doença, incluídas doenças cardiovasculares, respiratórias e endócrinas.²⁵ E ainda sobre as características demográficas e sociais, ressalta-se que o modelo assume a premissa de contato aleatório, e os valores de suas estimativas podem divergir das médias obtidas quando considerados os padrões específicos de contato de cada grupo (influência da heterogeneidade). Ao se interpretar o número de mortes esperadas no modelo, é importante lembrar: não foi considerada a possibilidade de aumento de mortes por falta de leitos em um possível colapso da rede assistencial.

Por fim, ressalta-se que os dados de leitos cadastrados, aqui apresentados, também devem ser interpretados com atenção à referência das metas de redução do impacto sobre a rede hospitalar. Isto porque não consideram as proporções reais de ocupação por outras condições clínicas, e os leitos adicionais que já vêm sendo implementados pelas autoridades de saúde.

A despeito de suas limitações, a presente análise reforça as conclusões sobre o efeito positivo das medidas de distanciamento social na redução do impacto da propagação da COVID-19 sobre a demanda da rede hospitalar. Dado o cenário alarmante projetado com a interrupção ou baixa adesão ao distanciamento social, é essencial que as autoridades em saúde locais considerem o monitoramento diário de indicadores de distanciamento, disseminação

da doença e disponibilidade de leitos hospitalares, no planejamento e implementação das políticas públicas de enfrentamento à COVID-19.

Contribuição dos autores

Zimmermann I, Sanchez M e Alves D discutiram e construíram o desenho inicial do estudo. Zimmermann I, Sanchez M e Brant J trabalharam na coleta de dados e concepção do modelo. Zimmermann I implementou o modelo, conduziu as simulações e sintetizou os principais resultados. Todos os autores contribuíram igualmente para a discussão e avaliação crítica dos resultados, tendo aprovado a versão final do manuscrito, e são responsáveis por todos os seus aspectos, incluindo a garantia de sua precisão e integridade.

Referências

1. Mohammadi M, Meskini M, Nascimento Pinto AL. 2019 Novel coronavirus (COVID-19) overview. *Z Gesundh Wiss* [Internet]. 2020 Apr [cited 2020 Sep 25];1-9. Available from: <https://doi.org/10.1007/s10389-020-01258-3>
2. Ministério da Saúde (BR). Painel coronavírus [Internet]. Brasília: Ministério da Saúde; 2020 [citado 2020 set 25]. Disponível em: <https://covid.saude.gov.br/>
3. Rothan HA, Byrareddy SN. The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak. *J Autoimmun* [Internet]. 2020 May [cited 2020 Sep 25];109:102433. Available from: <https://doi.org/10.1016/j.jaut.2020.102433>
4. Prem K, Liu Y, Russell TW, Kucharski AJ, Eggo RM, Davies N, et al. The effect of control strategies to reduce social mixing on outcomes of the COVID-19 epidemic in Wuhan, China: a modelling study. *Lancet Public Health* [Internet]. 2020 May [cited 2020 Sep 25];5(5):e261-70. Available from: [https://doi.org/10.1016/s2468-2667\(20\)30073-6](https://doi.org/10.1016/s2468-2667(20)30073-6)
5. Governo do Distrito Federal. Decreto nº 40.509, de 11 de março de 2020. Dispõe sobre as medidas para enfrentamento da emergência de saúde pública de importância internacional decorrente do novo coronavírus, e dá outras providências [Internet]. Diário Oficial do Distrito Federal, Brasília (DF), 2020 mar 11 [citado 2020 set 25]; Edição extra. Disponível em: http://www.sinj.df.gov.br/sinj/Norma/ad0fae78af5f4e50b46c7357b7ee8597/Decreto_40509_11_03_2020.html
6. Rede CoVida. Os impactos das medidas de distanciamento social e redução de fluxo intermunicipal na Bahia. *Bol CoVida* [Internet]. 2020 abr [citado 2020 set 25];1(2):19. Disponível em: https://covid19br.org/main-site-covida/wp-content/uploads/2020/04/BoletimCovida_2ed_Final.pdf
7. COVID-19 Brasil. Monitoramento e análises da situação do Coronavírus no Brasil [Internet]. São Paulo; 2020 [citado 2020 set 25]. Disponível em: <https://ciis.fmrp.usp.br/covid19/>
8. Organização Pan-Americana de Saúde – OPAS. Ministério da Saúde (BR). Universidade de Brasília. Butantã. Pressão hospitalar por COVID-19 [Internet]. [S.l.];2020. Disponível em: <https://covid-calc.org/>
9. Presidência da República (BR). Casa Civil. Avaliação de políticas públicas: guia prático de análise ex post [Internet]. Brasília: Presidência da República; 2018 [citado 2020 set 25]. 301 p. Disponível em: https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=34504

10. Instituto Brasileiro de Geografia e Estatística - IBGE. Diretoria de Pesquisas. Coordenação de População e Indicadores Sociais. Gerência de Estudos e Análises da Dinâmica Demográfica. Projeção da população do Brasil e Unidades da Federação por sexo e idade para o período 2000-2030 [Internet]. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística; 2020 [citado 2020 set 25]. Disponível em: <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?ibge/cnv/projpopuf.def>
11. Inloco. Mapa brasileiro da COVID-19 [Internet]. São Paulo: Inloco; 2020 [citado 27 abr 2020]. Disponível em: <https://www.inloco.com.br/pt/covid-19>
12. Ministério da Saúde (BR). Secretaria de Ciência Tecnologia e Insumos Estratégicos. Departamento de Ciência e Tecnologia. Diretrizes metodológicas: diretriz de avaliação econômica [Internet]. Brasília: Ministério da Saúde; 2014 [citado 2020 set 25]. 132 p. Disponível em: http://bvsms.saude.gov.br/bvs/publicacoes/diretrizes_metodologicas_diretriz_avaliacao_economica.pdf
13. Vynnycky E, White RG, Fine P. An introduction to infectious disease modelling. Oxford: Oxford University Press; 2010.
14. Rocha Filho TM, Santos FSG, Gomes VB, Rocha TAH, Croda JHR, Ramalho WM, et al. Expected impact of COVID-19 outbreak in a major metropolitan area in Brazil. medRxiv Prepr [Internet]. 2020 Mar [cited 2020 sep 25]. Available from: <https://doi.org/10.1101/2020.03.14.20035873>
15. Hill A. Modeling COVID-19 spread vs healthcare capacity [Internet]. [S.l.]; 2020 [cited 2020 Sep 25]. Available from: <https://alhill.shinyapps.io/COVID19seir/>
16. Penn University. CHIME model: discrete-time SIR modeling of infections/recovery [Internet]. [S.l.]; 2020 [cited 2020 Sep 25]. Available from: <https://code-for-philly.gitbook.io/chime/what-is-chime/sir-modeling>
17. Eikenberry SE, Mancuso M, Iboi E, Phan T, Eikenberry K, Kuang Y, et al. To mask or not to mask: modeling the potential for face mask use by the general public to curtail the COVID-19 pandemic. Infect Dis Model [Internet]. 2020.
18. World Health Organization - WHO. "Immunity passports" in the context of COVID-19 [Internet]. Geneva: World Health Organization; 2020 [cited 2020 Sep 25]. Available from: <https://www.who.int/news-room/commentaries/detail/immunity-passports-in-the-context-of-covid-19>
19. Governo do Distrito Federal. Secretaria de Saúde. Boletins Informativos DIVEP/CIEVES (COE). Boletins informativos sobre coronavirus (COVID-19). Brasília: GDF; 2020. Disponível em: <http://www.saude.df.gov.br/boletinsinformativos-divep-cieves/>
20. Briggs A, Claxton K, Sculpher M. Decision modelling for health economic evaluation. Oxford: Oxford University Press; 2011. 256 p.
21. Zimmermann I. Modelo de projeção da demanda por leitos de UTI por COVID-19. Mendeley Data [Internet]. 2020 set [citado 2020 set 25]. Disponível em: <http://dx.doi.org/10.17632/bypzkwmnrw>
22. Mellan TA, Hoeltgebaum HH, Mishra S, Whittaker C, Schnekenberg RP, Gandy A, et al. Report 21: estimating COVID-19 cases and reproduction number in Brazil. Imperial College London [Internet]. 2020 May [cited 2020 Sep 25]. Available from: <https://doi.org/10.25561/78872>
23. Tariq A, Lee Y, Roosa K, Blumberg S, Yan P, Ma S, et al. Real-time monitoring the transmission potential of COVID-19 in Singapore, March 2020. medRxiv Prepr [Internet]. 2020 Jun [cited 2020 Sep 25]. Available from: <https://dx.doi.org/10.1186%2Fs12916-020-01615-9>
24. Chowell G, Sattenspiel L, Bansal S, Viboud C. Mathematical models to characterize early epidemic growth: a review. Phys Life Rev [Internet]. 2016 Sep [cited 2020 sep 25];18:66-97. Available from: <https://doi.org/10.1016/j.plrev.2016.07.005>
25. Wang X, Fang X, Cai Z, Wu X, Gao X, Min J, et al. Comorbid chronic diseases and acute organ injuries are strongly correlated with disease severity and mortality among COVID-19 patients: a systemic review and meta-analysis. Research (Wash D C) [Internet]. 2020 Apr [cited 2020 Sep 25];2020:2402961. Available from: <https://doi.org/10.34133/2020/2402961>
26. Sanche S, Lin YT, Xu C, Romero-Severson E, Hengartner N, Ke R. The novel Coronavirus, 2019-nCoV, is highly contagious and more infectious than initially estimated. medRxiv Prepr [Internet]. 2020 Feb [cited 2020 Sep 25]. Available from: <https://doi.org/10.1101/2020.02.07.20021154>
27. Linton NM, Kobayashi T, Yang Y, Hayashi K, Akhmetzhanov AR, Jung S, et al. Incubation period and other epidemiological characteristics of 2019 novel coronavirus infections with right truncation:

- a statistical analysis of publicly available case data. *J Clin Med* [Internet]. 2020 Feb [cited 2020 Sep 25];9(2):538. Available from: <https://dx.doi.org/10.3390%2Fjcm9020538>
28. Verity R, Okell LC, Dorigatti I, Winskill P, Whittaker C, Imai N, et al. Estimates of the severity of coronavirus disease 2019: a model-based analysis. *Lancet Infect Dis* [Internet]. 2020 Mar [cited 2020 Sep 25];20(6):669-77. Available from: [https://doi.org/10.1016/S1473-3099\(20\)30243-7](https://doi.org/10.1016/S1473-3099(20)30243-7)
29. Neil M Ferguson, Laydon D, Nedjati-Gilani G, Imai N, Ainslie K, Baguelin M, et al. Impact of non-pharmaceutical interventions (NPIs) to reduce COVID-19 mortality and healthcare demand. Imperial College London [Internet]. 2020 [cited 2020 Sep 25]. Available from: <https://www.imperial.ac.uk/mrc-global-infectious-disease-analysis/covid-19/report-9-impact-of-npis-on-covid-19/>
30. Grasselli G, Zangrillo A, Zanella A, Antonelli M, Cabrini L, Castelli A, et al. Baseline characteristics and outcomes of 1591 patients infected with SARS-CoV-2 admitted to ICUs of the Lombardy Region, Italy. *JAMA* [Internet]. 2020 Apr [cited 2020 Sep 25];323(16):1574-81. Available from: <https://dx.doi.org/10.1001%2Fjama.2020.5394>

Abstract

Objective: To build scenarios and analyze the impact of social distancing policies on the spread of COVID-19 and the need for intensive care unit beds. **Methods:** Three dissemination scenarios were built according to level of adherence to social distancing measures in the context of Brazil's Federal District, based on a dynamic transition compartmental model and Monte Carlo simulations. The model's parameter values were based on official sources, indexed bibliographic databases and public data repositories. **Results:** The favorable scenario, with constant 58% adherence to social distancing, estimated a peak of 189 (interquartile range [IQR]: 57 – 394) ICU hospitalizations on March 3rd 2021. Absence of social distancing would result in an unfavorable scenario with a peak of 6,214 (IQR: 4,618 – 8,415) ICU hospitalizations probably as soon as July 14th 2020. **Conclusion:** The projections indicate the high impact of social distancing measures and emphasize the applicability of public indicators for COVID-19 monitoring.

Keywords: Coronavirus Infections; Intensive Care Units; Bed Occupancy; Health Evaluation; Public Policy.

Resumen

Objetivo: Construir escenarios y analizar el impacto de las políticas de distanciamiento social en la propagación de Covid-19 y la necesidad de camas en unidades de cuidados intensivos (UCI). **Métodos:** Con un modelo compartimental de transición dinámica y simulaciones de Monte Carlo, los escenarios de propagación se construyeron de acuerdo al nivel de adhesión de las medidas de distanciamiento social en el Distrito Federal, Brasil. Los parámetros se basaron en fuentes oficiales, bases de datos indexadas y repositorios de datos. **Resultados:** La adhesión al nivel de distanciamiento social con manutención constante de 58% fue el único escenario favorable, con un pico de 189 (intervalo intercuartil IIC: 57 a 394) admisiones en la UCI el 7/3/2021. La ausencia de distanciamiento implicaría en grave escenario, con un pico de 6.214 (IIC: 4.618 a 8.415) admisiones en UCI ya en la fecha probable de 14/7/2020. **Conclusión:** Las proyecciones muestran el alto impacto de las medidas de distanciamiento social y la aplicabilidad de indicadores públicos en el monitoreo.

Palabras clave: Infecciones por Coronavirus; Unidades de Cuidados Intensivos; Ocupación de Camas; Evaluación en Salud; Política Pública.

Recebido em 29/05/2020
Aprovado em 24/08/2020

Editora associada: Luciana Guerra Gallo – orcid.org/0000-0001-8344-9951

Material Suplementar 1 - Transições e equações

Após o contato com um indivíduo infectado, o indivíduo até então suscetível (S) se torna exposto (E) por um período de latência, este relacionado ao tempo médio de incubação da doença. Passado o período de latência, o indivíduo se torna infeccioso (I_1) e pode propagar a infecção enquanto não evolui para hospitalização (I_2 ou I_3) ou é removido (R) de circulação por quarentena. A hospitalização foi prevista para os indivíduos que, a partir do quadro leve (I_1), evoluem para um quadro grave (I_2) ou crítico (I_3). Coerentemente com o seguimento de pacientes com COVID-19, para os pacientes que progredem para o quadro crítico, é prevista a transição para o óbito de acordo com uma letalidade específica da doença (μ). Em cada um dos compartimentos de indivíduos hospitalizados, também está prevista a possibilidade de remoção do modelo de acordo com a duração da hospitalização (γ). As transições entre os compartimentos foram solucionadas por um sistema de equações, obedecendo à igualdade de que a população total (N) representasse a soma dos indivíduos suscetíveis (S), expostos (E), infectados (I), removidos (R) e mortos (M) a cada instante t do modelo. O sistema de equações diferenciais do modelo é apresentado nas equações 1 a 8:

$$S(t+1) = S(t) - (\beta I_1) \frac{S(t)}{N} \quad (1)$$

$$E(t+1) = E(t) + (\beta I_1) \frac{S(t)}{N} - \alpha E(t) \quad (2)$$

$$I_1(t+1) = I_1(t) + \alpha E(t) - (\gamma_1 + p_1) I_1(t) \quad (3)$$

$$I_2(t+1) = I_2(t) + p_1 I_1(t) - (\gamma_2 + p_2) I_2(t) \quad (4)$$

$$I_3(t+1) = I_2(t) + p_2 I_2(t) - (\gamma_3 + \mu) I_3(t) \quad (5)$$

$$R(t+1) = R(t) + \gamma_1 I_1(t) + \gamma_2 I_2(t) + \gamma_3 I_3(t) \quad (6)$$

$$M(t+1) = M(t) + \mu I_3(t) \quad (7)$$

$$N = S(t) + E(t) + I_1(t) + I_2(t) + I_3(t) + R(t) + M(t) \quad (8)$$

A seguir, são apresentadas equações complementares ao sistema de equações diferenciais do modelo, onde f_{hosp} refere-se à fração de indivíduos que evoluem para hospitalização, f_{uti} à fração de indivíduos hospitalizados que evoluem para o quadro crítico, e ifr à letalidade:

$$\alpha = (\text{tempo de incubação})^{-1} \quad (9)$$

$$\delta = \frac{ifr}{(f_{hosp} f_{uti})} \quad (10)$$

$$\mu = \delta \frac{1}{(\text{tempo até a morte} - \text{tempo até isolamento ou hospitalização} - \text{tempo em leito regular})} \quad (11)$$

$$\gamma_1 = f_{hosp} (\text{tempo até isolamento ou hospitalização})^{-1} \quad (12)$$

$$\gamma_2 = (1 - f_{uti}) (\text{tempo em leito regular})^{-1} \quad (13)$$

$$\gamma_3 = (1 - \delta) (\text{tempo em leito de uti})^{-1} \quad (14)$$

$$p_1 = (\text{tempo até isolamento ou hospitalização})^{-1} - \gamma_1 \quad (15)$$

$$p_2 = f_{uti} (\text{tempo em leito regular})^{-1} \gamma_1 \quad (16)$$

Relação entre o distanciamento social e o coeficiente de transmissão

Com o intuito de simular a propagação da doença mediante os efeitos do distanciamento social, adotou-se o cálculo do coeficiente de transmissão (β), a partir das estimativas epidêmicas e de isolamento social disponíveis.^{17,24} Para tanto, considera-se aqui a relação dinâmica de que a taxa efetiva de contatos (β) em cada instante segue a função de um fator de transmissibilidade (τ), característica mais estável e muito associada à virulência do patógeno e de um fator de contato dos indivíduos expostos (c), fator mais dinâmico e dependente do isolamento social, ou seja, $\beta = \tau c$. Assim, os níveis de isolamento, registrados diariamente na série temporal do Distrito Federal, são imputados no modelo como o complemento do fator c . Da mesma forma, semelhantemente ao proposto por Eikenberry et al.,¹⁷ o valor de τ foi estimado por meio de calibração aos valores da série temporal do número de internações em UTI por COVID-19 no Distrito Federal, no período de 22/3/2020 a 21/5/2020.

Tendo-se o coeficiente de transmissão β , também foi calculado o número de reprodução instantâneo (R_t) de cada dia, no período analisado, com o intuito de ilustrar a dinâmica da propagação conforme os cenários propostos. Coerentemente com abordagens metodológicas prévias, o número de reprodução instantâneo (R_t) considera as taxas específicas de entrada e saída do compartimento infeccioso, por meio da equação 17:

$$R_t = \frac{\beta(t) S(t)}{(\rho_1 + \gamma_1)} \quad (17)$$

Material Suplementar 2 – Taxas de infecção, hospitalização e letalidade esperadas para a COVID-19, de acordo com a estrutura etária, no Distrito Federal, Brasil

Faixa etária (anos)	Habitantes	Frequência (%)	Taxa de infecção (por 10 mil hab.)	Taxa de hospitalização de infectados (%)	Letalidade de infectados (%)
0-9	419.157	13,00	0,36	0,00	0,00
10-19	450.663	13,98	13,73	0,04	0,01
20-29	594.106	18,43	14,92	1,04	0,03
30-39	570.790	17,71	14,24	3,43	0,08
40-49	483.968	15,02	13,99	4,25	0,16
50-59	336.382	10,44	15,98	8,16	0,60
60-69	207.838	6,45	15,33	11,80	1,93
70-79	110.260	3,42	15,14	16,60	4,28
≥80	49.884	1,55	12,87	18,40	7,80
Total	3.223.048	100,00	13,02	4,57	0,58

Fontes: Instituto Brasileiro de Geografia e Estatística (IBGE)¹⁰ e Verity et al.²⁸

Material Suplementar 3 – Série histórica de casos de COVID-19 confirmados acumulados, internações em unidade de terapia intensiva, número de óbitos e percentual de isolamento social no Distrito Federal, Brasil

Data	Casos acumulados	Internações em UTI ^a	Óbitos acumulados	Percentual de isolamento
1/3/2020	1	–	–	0,4090
2/3/2020	1	–	–	0,2740
3/3/2020	1	–	–	0,2810
4/3/2020	1	–	–	0,2930
5/3/2020	1	–	–	0,2960
6/3/2020	1	–	–	0,2900
7/3/2020	1	–	–	0,3180
8/3/2020	1	–	–	0,3980
9/3/2020	1	–	–	0,2891
10/3/2020	1	–	–	0,2880
11/3/2020	2	–	–	0,2770
12/3/2020	2	–	–	0,3220
13/3/2020	2	–	–	0,3190
14/3/2020	6	–	–	0,3650
15/3/2020	8	–	–	0,4260
16/3/2020	13	–	–	0,3430
17/3/2020	22	–	–	0,3430
18/3/2020	26	–	–	0,3670
19/3/2020	42	–	–	0,3990
20/3/2020	87	–	–	0,4430
21/3/2020	100	–	–	0,5670
22/3/2020	117	1	–	0,6560
23/3/2020	133	1	1	0,5590
24/3/2020	177	1	1	0,6110
25/3/2020	182	6	1	0,5710
26/3/2020	201	6	1	0,5610
27/3/2020	241	8	1	0,5340
28/3/2020	260	13	1	0,5700
29/3/2020	298	19	2	0,5990
30/3/2020	312	20	2	0,5761
31/3/2020	333	30	3	0,5010
1/4/2020	370	30	4	0,4730
2/4/2020	400	41	6	0,4980
3/4/2020	419	40	9	0,4870
4/4/2020	456	38	10	0,5100
5/4/2020	468	41	12	0,5770
6/4/2020	485	37	12	0,4890
7/4/2020	503	40	12	0,4720
8/4/2020	509	42	13	0,4640
9/4/2020	527	35	14	0,4470
10/4/2020	556	33	14	0,5480
11/4/2020	592	32	14	0,4760
12/4/2020	618	33	16	0,5370
13/4/2020	641	30	17	0,4690
14/4/2020	651	28	19	0,4680
15/4/2020	688	30	22	0,4750
16/4/2020	727	29	22	0,4570
17/4/2020	756	25	24	0,4350
18/4/2020	796	26	24	0,4780
19/4/2020	860	28	24	0,5420
20/4/2020	875	28	24	0,4630
21/4/2020	913	29	24	0,5360
22/4/2020	959	30	25	0,4500

continua

continuação

Data	Casos acumulados	Internações em UTI ^a	Óbitos acumulados	Percentual de isolamento
23/4/2020	968	30	26	0,4580
24/4/2020	1.012	32	26	0,4330
25/4/2020	1.020	34	27	0,4610
26/4/2020	1.125	34	27	0,5280
27/4/2020	1.189	35	28	0,4450
28/4/2020	1.230	36	28	0,4410
29/4/2020	1.313	38	28	0,4300
30/4/2020	1.423	38	30	0,4210
1/5/2020	1.546	43	31	0,4930
2/5/2020	1.605	45	32	0,4440
3/5/2020	1.720	49	33	0,4960
4/5/2020	1.793	59	33	0,4370
5/5/2020	1.837	56	34	0,4240
6/5/2020	2.046	60	35	0,4220
7/5/2020	2.258	60	35	0,4290
8/5/2020	2.442	64	37	0,4010
9/5/2020	2.576	66	39	0,4250
10/5/2020	2.682	72	42	0,4540
11/5/2020	2.799	78	44	0,4290
12/5/2020	2.979	87	46	0,4280
13/5/2020	3.192	92	48	0,4210
14/5/2020	3.416	94	51	0,4190
15/5/2020	3.786	86	55	0,4120
16/5/2020	4.140	84	56	0,4472
17/5/2020	4.368	116	59	0,5176
18/5/2020	4.618	121	66	0,4248
19/5/2020	4.853	125	72	0,4205
20/5/2020	5.271	142	78	0,4120
21/5/2020	5.542	138	84	0,4121
22/5/2020	5.948	–	90	0,3986
23/5/2020	6.248	–	95	0,4330
24/5/2020	6.638	–	104	0,5137
25/5/2020	6.930	–	114	0,4214
26/5/2020	7.210	–	124	0,4111
27/5/2020	7.761	–	133	0,4054
28/5/2020	8.300	–	142	0,4084
29/5/2020	8.722	–	154	0,3922
30/5/2020	9.474	–	162	0,4228
31/5/2020	9.780	–	170	0,4950
1/6/2020	10.510	–	171	0,4085
2/6/2020	11.256	–	177	0,4040
3/6/2020	11.398	–	181	0,3948
4/6/2020	12.923	–	196	0,3875
5/6/2020	14.208	–	202	0,3884
6/6/2020	15.850	–	208	0,3983
7/6/2020	16.623	–	214	0,4769
8/6/2020	16.948	–	226	0,3927
9/6/2020	18.090	–	236	0,3828
10/6/2020	19.433	–	256	0,3936
11/6/2020	20.507	–	274	0,4451
12/6/2020	21.396	–	282	0,3727
13/6/2020	21.959	–	293	0,4054
14/6/2020	22.871	–	304	0,4830
15/6/2020	23.684	–	319	0,3953
16/6/2020	25.379	–	348	0,4051
17/6/2020	27.140	–	365	0,3875
18/6/2020	28.521	–	379	0,3966

continua

continuação

Data	Casos acumulados	Internações em UTI ^a	Óbitos acumulados	Percentual de isolamento
19/6/2020	30.902	–	396	0,3562
20/6/2020	32.238	–	405	0,4042
21/6/2020	33.227	–	423	0,4839
22/6/2020	34.148	–	449	0,4039
23/6/2020	35.368	–	475	0,3969
24/6/2020	37.254	–	495	0,3932
25/6/2020	38.871	–	509	0,3940
26/6/2020	41.326	–	532	0,3811
27/6/2020	42.766	–	537	0,4190
28/6/2020	44.905	–	548	0,4926
29/6/2020	47.071	–	559	0,4216
30/6/2020	49.218	–	587	0,4100
1/7/2020	50.676	–	620	0,4020
2/7/2020	52.281	–	631	0,4040
3/7/2020	53.996	–	643	0,3850
4/7/2020	55.760	–	671	0,4090
5/7/2020	57.854	–	699	0,4820
6/7/2020	60.383	–	726	0,4130
7/7/2020	62.694	–	767	0,3950
8/7/2020	64.314	–	801	0,3900
9/7/2020	65.677	–	823	0,4000
10/7/2020	67.297	–	856	0,3920
11/7/2020	68.406	–	871	0,4180
12/7/2020	70.712	–	902	0,4870
13/7/2020	72.284	–	930	0,4130
14/7/2020	73.654	–	960	0,4130
15/7/2020	75.379	–	1.001	0,4020
16/7/2020	77.621	–	1.037	0,4030
17/7/2020	79.400	–	1.060	0,3570
18/7/2020	81.163	–	1.075	0,3940
19/7/2020	82.412	–	1.085	0,4850
20/7/2020	84.287	–	1.112	0,4080
21/7/2020	86.076	–	1.158	0,4070
22/7/2020	87.801	–	1.176	0,3960
23/7/2020	90.023	–	1.218	0,3960
24/7/2020	92.414	–	1.244	0,3880
25/7/2020	94.187	–	1.275	0,4110
26/7/2020	96.332	–	1.308	0,4810
27/7/2020	98.480	–	1.339	0,4070
28/7/2020	100.726	–	1.391	0,4000
29/7/2020	102.342	–	1.419	0,3970
30/7/2020	104.442	–	1.444	0,3970
31/7/2020	106.292	–	1.469	0,3860

a) UTI: unidade de terapia intensiva – dados disponíveis até a data de 21/5/2020.

Fontes: Boletins Epidemiológicos locais e base pública da Inloco.¹¹

Material Suplementar 4 – Ilustração das funções de distribuição de probabilidade dos principais parâmetros do modelo

