



Este trabalho está licenciado sob uma licença Creative Commons Attribution 4.0 International License. Fonte: <https://preprints.scielo.org/index.php/scielo/preprint/view/574>. Acesso em: 02 jun. 2020.

REFERÊNCIA

ZIMMERMANN, Ivan et al. Demanda por leitos de UTI pela COVID-19 no Distrito Federal, Brasil : uma análise do impacto das medidas de distanciamento social com simulações de Monte Carlo. **SciELO Preprints**, 2020. DOI: <https://doi.org/10.1590/SciELOPreprints.574>. Disponível em: <https://preprints.scielo.org/index.php/scielo/preprint/view/574>. Acesso em: 02 jun. 2020.

Demanda por leitos de UTI pela COVID-19 no Distrito Federal, Brasil: uma análise do impacto das medidas de distanciamento social com simulações de Monte Carlo

Demand for ICU beds by COVID-19 in the Federal District, Brazil: an analysis of the impact of social distance measures with Monte Carlo simulations

Demanda de camas de UCI por COVID-19 en el Distrito Federal, Brasil: un análisis del impacto de las medidas de distancia social con simulaciones de Monte Carlo

Autores: Ivan Zimmermann¹, Mauro Sanchez¹, Jonas Brant¹, Domingos Alves²

Resumo

Objetivos: analisar o impacto das políticas de distanciamento social sobre a propagação da COVID-19 e a necessidade de leitos de unidades de terapia intensiva. **Métodos:** com um modelo compartimental de transição dinâmica e simulações de Monte Carlo foram construídos cenários de propagação de acordo com o nível de adesão das medidas de distanciamento social no contexto do Distrito Federal, Brasil. Os valores dos parâmetros foram baseados em fontes oficiais, bases indexadas e repositórios públicos de dados. **Resultados:** a manutenção da adesão ao nível de 58% de isolamento foi o único cenário favorável, com um pico de até 792 (IQR: 447 a 1.262) internações em UTI entre 05/11/2020 e 15/01/2021. A ausência do distanciamento implicaria um pico de até 7.331 (IQR: 5.427 a 9.696) internações em UTI. **Conclusão:** as projeções corroboram o efeito positivo das medidas de distanciamento social e a aplicabilidade de indicadores no seu monitoramento.

Palavras-chave: Infecções por Coronavirus; Previsões; Simulação; Avaliação em Saúde; Política Pública

Afilições: ¹ Departamento de Saúde Coletiva, Faculdade de Ciências da Saúde, Universidade de Brasília; ² Departamento de Medicina Social, Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo

Contato:

Ivan Zimmermann
Departamento de Saúde Coletiva
Faculdade de Ciências da Saúde
Universidade de Brasília
Brasília, DF, Brasil
CEP 70910-900
Email: ivan.zimmermann@unb.br



Abstract

Objectives: to analyze the impact of social distance policies on the spread of COVID-19 and the need for beds in intensive care units. **Methods:** based on a dynamic transition compartmental model and Monte Carlo simulations, propagation scenarios were built according to the level of adherence of the social distance measures in the context of the Federal District, Brazil. The parameter values were based on official sources, indexed databases and public data repositories. **Results:** maintaining adherence to the 58% isolation level was the only favorable scenario, with a peak of up to 792 (IQR: 447 to 1,262) ICU admissions between 11/05/2020 and 1/15/2021. The absence of social distance would imply a peak of up to 7,331 (IQR: 5,427 to 9,696) ICU admissions. **Conclusion:** the projections corroborate the positive effect of social distance measures and the applicability of indicators in their monitoring.

Keywords: Coronavirus Infections; Forecasting; Simulation Technique; Health Evaluation; Public Policy

Resumen:

Objetivos: analizar el impacto de las políticas de distancia social en la propagación de COVID-19 y la necesidad de camas en unidades de cuidados intensivos. **Métodos:** con un modelo de transición dinámica y simulaciones de Monte Carlo, los escenarios de propagación se construyeron de acuerdo con el nivel de adherencia de las medidas de distancia social en el Distrito Federal, Brasil. Los parámetros se basaron en fuentes oficiales, bases de datos indexadas y repositorios de datos. **Resultados:** mantener la adherencia al nivel de aislamiento del 58% fue el único escenario favorable, con un pico de hasta 792 (IQR: 447 a 1,262) admisiones en la UCI entre el 11/05/2020 y el 15/1/2021. La ausencia de distancia implicaría un pico de 7,331 (IQR: 5,427 a 9,696) admisiones en la UCI. **Conclusión:** las proyecciones corroboran el efecto positivo de las medidas de distancia social y la aplicabilidad de los indicadores en su seguimiento.

Palabras-clave: Infecciones por Coronavirus; Predicción; Simulación; Evaluación en Salud; Política Pública

Introdução

A COVID-19, doença decorrente da infecção pelo vírus Sars-CoV-2 que, dentre outras manifestações clínicas, pode acarretar em síndrome respiratória aguda grave (SARS) ¹, teve seu primeiro caso confirmado no Brasil no dia 25/02/2020 ² e em 03/05/2020, o país já contava oficialmente com mais de 100.000 casos e 7.000 óbitos ³. Dado seu amplo alcance e a rápida propagação, o potencial da doença levar a rede hospitalar ao colapso, sobretudo em relação à disponibilidade de leitos de UTI, fazem com que esta seja considerada uma condição muito grave para a saúde pública ^{1,4,5}.

Embora existam relatos de experiências com tratamentos e iniciativas para a obtenção de uma vacina, até o momento, não há comprovação robusta de eficácia de intervenções farmacológicas para a prevenção ou tratamento dessa condição clínica⁶. Nesse sentido, a proteção de profissionais de saúde, isolamento de indivíduos infectados e a adoção de intervenções não farmacológicas, como as políticas públicas de distanciamento social, se apresentam como a opção mais factível de enfrentamento à COVID-19⁷⁻¹¹. Com o intuito de monitorar e orientar as decisões de políticas públicas em relação à COVID-19, uma série de iniciativas e redes têm unido esforços e disponibilizado ferramentas de predição de casos e projeção de necessidade de leitos e equipamentos hospitalares^{3,5,12-18}.

A análise de dados em políticas públicas, no que diz respeito à avaliação de impacto, é um campo com intensa necessidade de dados robustos para suas possíveis inferências¹⁹⁻²¹. Entretanto, em cenários com limitação temporal na disponibilidade de dados, é de grande valor a construção de modelos e contrafactuais (cenários possíveis, mas não necessariamente reais) para identificar as tendências e projeções dos possíveis impactos de uma determinada política pública¹⁹.

Tomando como base o contexto da população de Brasília (DF) e o auxílio de um modelo matemático com simulações de Monte Carlo, foi conduzida uma análise de possíveis cenários de propagação da COVID-19 em relação às medidas de distanciamento social e seu impacto sobre a demanda por leitos de UTI.

Métodos

Contexto

Como caso desta análise, considera-se a conformação de todas as regiões administrativas integrantes do Distrito Federal, com uma população estimada em 3.223.048 habitantes no ano de 2020, de acordo com projeções do Instituto Brasileiro de Geografia e Estatística – IBGE ²². O primeiro caso infecção pelo vírus Sars-CoV-2 em Brasília foi confirmado no dia 05/03/2020 ². No dia 11/03/2020, com vigência em todo o Distrito Federal, foram decretadas as primeiras medidas locais de distanciamento social para o enfrentamento do novo coronavírus, incluindo a suspensão de eventos com público superior a cem pessoas e as atividades educacionais em todas as escolas, universidades e faculdades ²³. Adicionalmente, bares e restaurantes também deveriam garantir a distância mínima de dois metros entre suas mesas. Desde então, o decreto local sobre tais medidas tem sido reformulado e atualizado ^{24,25}, ampliando, desde o dia 14/03/2020, a suspensão de outras atividades coletivas, incluindo cinemas, teatros, museus, academias de esporte, shoppings centers, feiras populares, clubes recreativos, parques ecológicos, boates, casas noturnas, entre outros. Na data de 21/04/2020, além das medidas já aplicadas, o governo local passou a adotar a testagem populacional de indivíduos sintomáticos, ampliando postos de coleta e triagem de indivíduos sintomáticos fora das unidades de saúde ^{26,27}.

Com o intuito de identificar uma referência da capacidade hospitalar instalada, foram consultados os números de leitos de UTI adultos cadastrados na região de acordo com banco de dados do Cadastro Nacional de Estabelecimentos de Saúde (CNES) ²⁸

Indicadores de isolamento social

De maneira complementar, buscando contextualizar a adesão da população às medidas de distanciamento social de acordo com as políticas instituídas, foram também consultados os dados públicos do indicador de isolamento social no DF no período de estudo, disponibilizados pela empresa de tecnologia Inloco ¹⁷. Tal indicador tem auxiliado iniciativas do monitoramento da propagação 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.

Estrutura do modelo

Para estimar a necessidade de leitos de UTI de acordo com a propagação da doença, buscou-se a construção de um modelo matemático. Considerando as diretrizes metodológicas brasileiras disponíveis ²⁹ e os fundamentos práticos da modelagem de doenças infecciosas ^{30,31}, decidiu-se pela concepção de um modelo compartimental de transição dinâmica em tempo discreto. Neste modelos, derivados da clássica proposta do modelo SIR de Kermack e McKendrick, a transição entre os compartimentos (ou estados de saúde) é representada por um sistema de equações diferenciais que dependem, dentre outros pontos, do número de infectados (I), da taxa de contatos efetivos ou coeficiente de transmissão (β), latência (α) e recuperação (γ).

Adota-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^{15,16,30,32,33}, assim como o impacto de intervenções não farmacológicas como o uso de máscaras sobre a propagação comunitária da COVID-19³³. Nesta proposta, o modelo para a relação diária entre o número de indivíduos Suscetíveis (S), Expostos (E), Infectados (I) e Removidos (R) é representado na Figura 1.




Figura 1. Representação da estrutura do modelo dinâmico compartimental adotado. Fonte: Adaptado de Hill et al. (2020)

O compartimento I_3 se refere aos pacientes com quadro crítico, que evoluem para a necessidade de internação em terapia intensiva (UTI). As transições entre os compartimentos foram solucionadas por um sistema de equações obedecendo a 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 (8).

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

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

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

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

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

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

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

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

Principais pressupostos

Dentre outros pontos citados ao longo do texto, pode-se destacar como principais pressupostos do modelo:

- 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;
- Semelhante a abordagens prévias baseadas em modelos SEIR da COVID-19^{33,34}, assume-se que os indivíduos hospitalizados não estejam efetivamente expostos à população em geral e, portanto, não contribuem para o cálculo da força de infecção na comunidade;
- Não é prevista a possibilidade de reinfecção de indivíduos recuperados. Apesar de contemplar uma expectativa social e estar coerente com dados iniciais de algumas pesquisas pré-clínicas³⁵, ainda não há evidências sobre o grau com que as pessoas que desenvolvam anticorpos estejam de fato protegidas de uma nova infecção³⁶;

- Não sendo objetivo da análise, o presente modelo não considera o potencial aumento da mortalidade devido à falta de leitos. Assim, é importante considerar que as taxas de letalidade observadas no modelo podem estar subestimadas em um cenário de indisponibilidade de leitos.
- As estimativas de contato efetivos assumem o pressuposto da mistura homogênea (*random mixing*)³⁰, onde o indivíduo infectado pode entrar em contato com um indivíduo suscetível de acordo com uma mesma probabilidade média.

Mais detalhes sobre o modelo estão disponíveis em material suplementar.

Cenários

No horizonte temporal de 1 ano, tomando como referencial a data inicial de 22/03/2020, dado o período de dados disponíveis de internações em UTI por COVID-19 e uma margem de 10 dias entre o início das medidas de distanciamento social e o pico dos níveis de isolamento social obtido no DF, foram construídos 3 cenários de propagação da COVID-19 para analisar o impacto potencial sobre a necessidade de atendimento hospitalar:

- Cenário A: Perfil de propagação sem adesão às medidas de distanciamento social
- Cenário B: Perfil de propagação com manutenção da adesão ao distanciamento social
- Cenário C: Perfil de propagação com a dinâmica observada do nível de distanciamento social

O primeiro cenário (Cenário A) tem o objetivo de representar 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 no modelo a estimativa média de isolamento social observada nos últimos 10 dias antes do decreto local no dia 11/03/2020. Sendo assim, adota-se uma taxa fixa de contato efetivos (β) no modelo.

O segundo cenário (Cenário B) busca representar o perfil de propagação da infecção e de necessidade de leitos com a manutenção do nível de isolamento social médio obtido nos primeiros 10 dias após o pico de isolamento social. Neste cenário, o modelo também adota uma taxa fixa de contato efetivos (β).

Por fim, o Cenário C busca representar a dinâmica de isolamento social observada no DF 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 ³⁷, são também estimadas metas de isolamento populacional de acordo com a demanda por leitos de UTI.

Parâmetros e incertezas

Com o intuito de aproximação do modelo de análise à realidade local, além do tamanho da população, foi considerada a estrutura etária do DF para o ajuste das taxas esperadas de letalidade e hospitalização para a região (Tabela S1). A partir dos boletins oficiais da Secretaria de Saúde ², foram levantados os números de casos por data de início de sintomas, internações em UTI e óbitos por COVID-19 no DF. A série completa de internações em UTI, óbitos e níveis de isolamento social disponíveis para o período de análise são apresentados na Tabela S2.

Na ausência de dados locais dos demais parâmetros, foram também consultadas publicações indexadas na base Pubmed (<https://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 (<https://midasnetwork.us/COVID-19>). Os dados extraídos incluíram as estimativas pontuais e incertezas (erro padrão, intervalos de confiança ou distribuições de probabilidade). Os valores dos principais parâmetros considerados no modelo aqui proposto, acompanhados de sua, incerteza, descrição e fontes são apresentados na Tabela 1.

Para considerar o impacto das incertezas paramétricas nos resultados do modelo, as análises foram conduzidas em uma abordagem estocástica (probabilística) fazendo uso de simulações de Monte Carlo (MC) em nível de valor esperado (2ª ordem) ^{38,39}. Baseando-se nas características das variáveis ^{38,39}, foram ajustadas distribuições *a priori* de probabilidade para os principais parâmetros (Figura S1). Na ausência de intervalos nas fontes de dados, foi considerada a reamostragem com reposição (*bootstrap*) para estimar a incerteza paramétrica ^{38,39}. Os resultados foram resumidos por meio das medianas e intervalos de cobertura das simulações ⁴⁰⁻⁴³.

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 e de internações em UTI preditos pelo modelo e observados na série temporal em análise ⁴⁴. 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

Tabela 1. Relação de valores, incertezas, 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	<i>Sanche et al, 2020⁶¹</i>
Duração - leve (dias)	3,65	3,21	4,09	Gama	Duração do quadro até isolamento ou hospitalização	<i>Linton et al. 2020⁶²</i>
Quadro grave (%)	4,57	2,72	9,32	Beta	Proporção de infectados que terão quadro graves ou críticos (hospitalização)	<i>Verity et al, 2020⁶³</i>
Tempo de internação (dias)	8,00	6,00	10,00	Lognormal	Tempo médio de internação em enfermaria	<i>Ferguson et al, 2020⁸</i>
Internação em UTI (%)	46,30	44,31	48,06	Beta	Percentual de pacientes graves que necessitam cuidados intensivos	<i>Boletins Epidemiológicos²</i>
Tempo em UTI (dias)	9,00	6,00	13,00	Lognormal	Tempo médio de internação em UTI	<i>Grasselli et al, 2020⁵⁸</i>
Taxa de letalidade (%)	0,576	0,315	1,140	Beta	Letalidade de infectados ajustada para a região	<i>Verity et al, 2020⁶³</i>
Tempo até a morte (dias)	17,80	16,02	19,58	Lognormal	Tempo médio do início dos sintomas até a morte	<i>Verity et al, 2020⁶³</i>
Mortalidade na UTI (%)	27,23	12,85	47,81	Não se aplica	Probabilidade de morte em UTI	<i>Calibrado pela letalidade</i>

Fonte: Elaboração própria

parâmetros de calibração foi realizado com o método dos mínimos quadrados não linear⁴⁵ com auxílio 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 dados⁴⁶.

Resultados

Conforme as fontes oficiais consultadas, até a data final de obtenção de dados para o modelo, 21/05/2020, haviam sido confirmados 5.542 casos e 84 óbitos por COVID-19 no DF². Ao considerar a data do primeiro decreto local sobre as medidas de distanciamento, é possível observar que houve uma importante adesão inicial da população às medidas, dado o aumento gradual do índice de isolamento social ao longo dos dias seguintes ao decreto, saindo de uma média de 30,04% entre 02/03/2020 e 11/03/2020, para uma média de 57,38% entre 22/03/2020 e 30/04/2020 (Figura 2).

Considerando os registros de casos de acordo com a data de início dos sintomas, todos os cenários iniciaram as simulações na data de 22/03/2020 com uma estimativa média de 366 indivíduos infectados (I_1) e de 732 expostos (E) – dada a existência de uma R_t mínima de 2 sem o isolamento social. Com um RMSE de 11,9 e de 11,8 nos valores preditos de internações em UTI e óbitos, respectivamente, o valor do parâmetro τ foi estimado em 0,7712 na calibração do modelo. De acordo o banco de dados do CNES, o DF possuía, até o mês de abril, um total de 944 leitos de UTI adulto, sendo 203 desses públicos. A seguir, são apresentados os resultados de cada um dos cenários.




Figura 2. Evolução do isolamento social no Distrito Federal de acordo a data da implementação das medidas de enfrentamento à COVID-19. Fonte: Elaborado a partir dos dados de InLoco (2020)

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

No primeiro cenário, o coeficiente de transmissão é calculado assumindo um nível de isolamento social de 30%, coerente com os valores médios observados até a data de 11/03/2020.

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 de até 7.331 (IQR: 5.427 a 9.696) internações em UTI em alguma data provável entre 27/06/2020 e 05/07/2020. No entanto, de acordo com os dados do CNES, o número total de leitos públicos de UTI cadastrados já teria sido ultrapassado entre as datas de 30/04/2020 e 07/05/2020. Esta demanda superior ao número de leitos públicos de UTI cadastrados seria mantida por pelo menos 127 (IQR: 119 a 136) dias.

No horizonte de 1 ano, seria provável um pico de infecções ativas de 225.190 (IQR: 197.193 a 257.882) na data próxima de 08/06/2020. Neste ritmo, até a data de 31/03 do próximo ano, seria prevista a infecção de até 79,4% (IQR: 76,6% a 81,9%) da população do DF. Mesmo que fosse possível atender todos os infectados, seria prevista a morte de 16.934 (IQR: 11.516 e 23.973) indivíduos – letalidade esperada de 0,67% (IQR: 0,45% a 0,94%).

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

Considerando a hipótese de que tivesse sido mantida a adesão ao nível de isolamento social médio de 57,38%, obtido no período inicial das medidas de distanciamento, este cenário previa um pico de até 792 (IQR: 447 a 1.262) internações em UTI entre 05/11/2020 e 15/01/2021. Apesar de ser ainda um número acima da capacidade atual de leitos públicos de UTI cadastrados, seria menos provável que tal

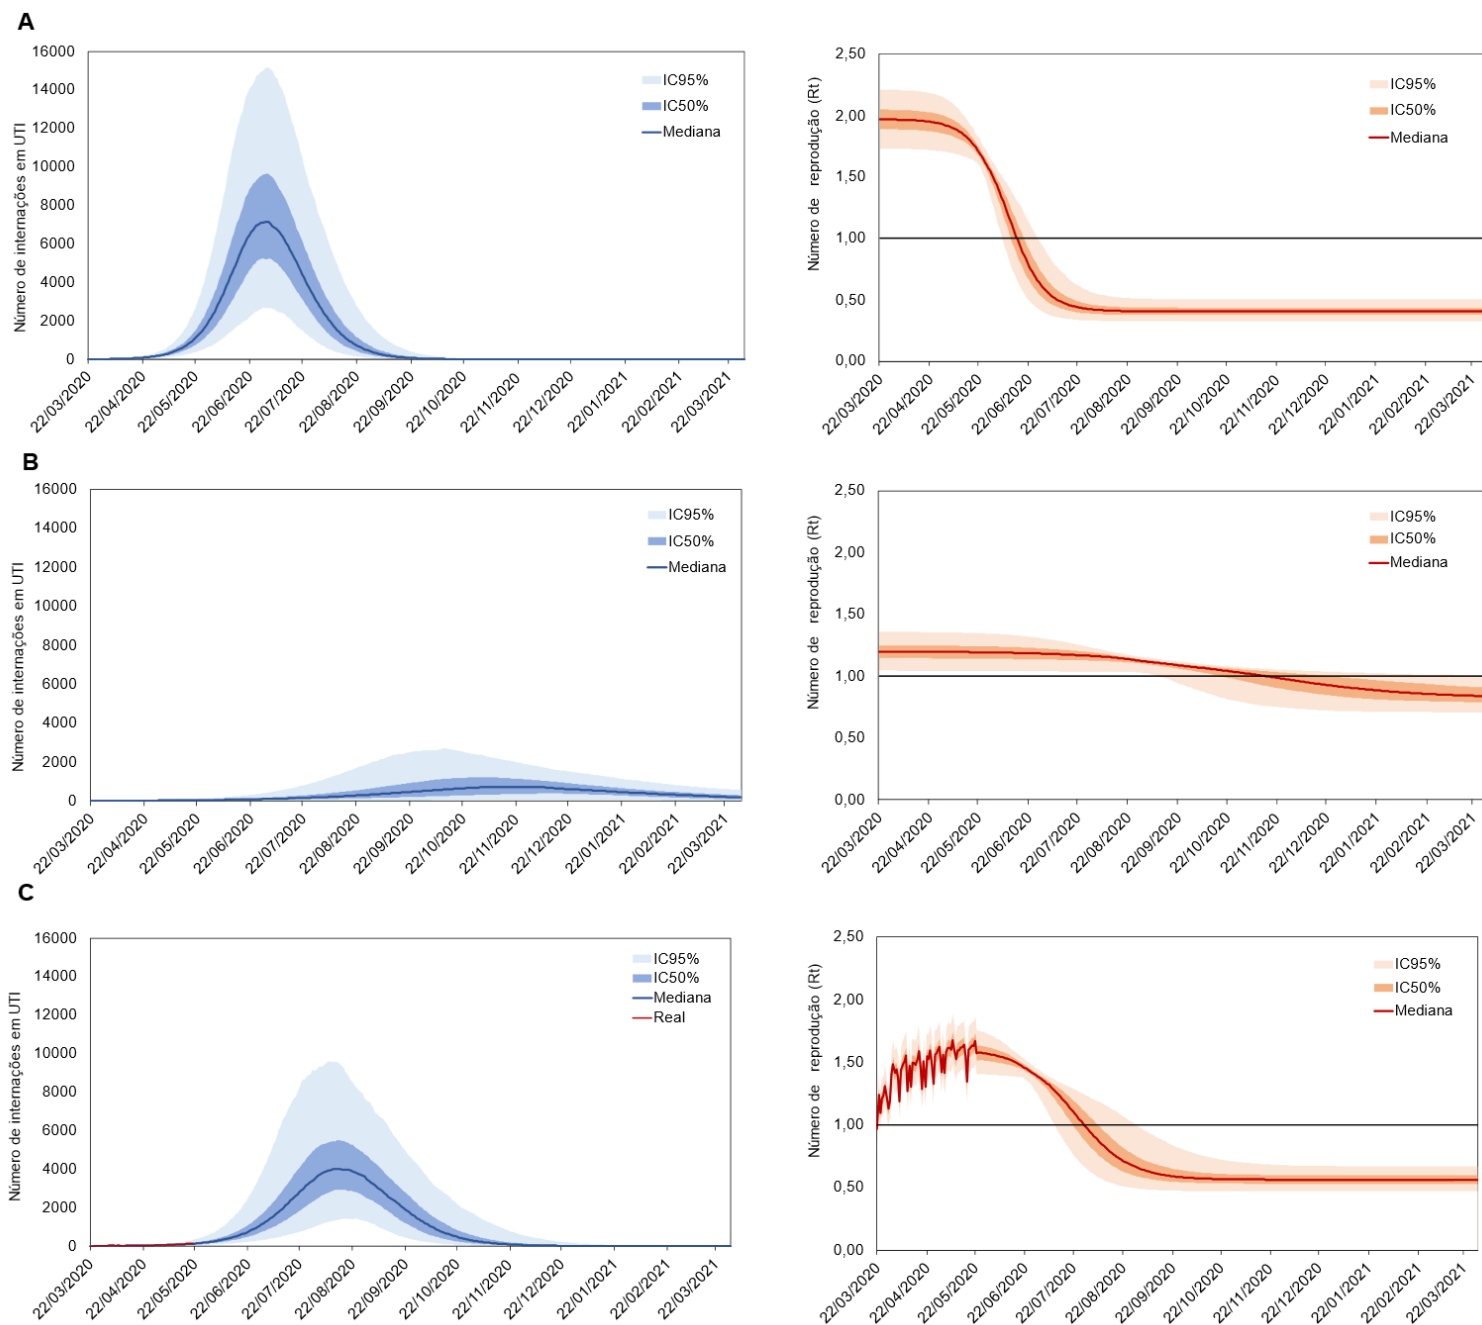


Figura 3. Projeções da demanda por leitos de UTI pela COVID-19 e do do número de reprodução (Rt) no Distrito Federal, Brasil nos cenários: A) Perfil de propagação sem adesão às medidas de distanciamento social; B) Perfil de propagação com manutenção da adesão ao distanciamento social e C) Perfil de propagação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

demanda ultrapassasse o total de leitos incluindo os leitos públicos, privados e as possíveis ampliações.

Ao longo do período simulado de 1 ano, o número total de indivíduos infectados (incluindo os casos assintomáticos, leves, graves e críticos) poderia atingir um pico de 23.202 (IQR: 13.043 a 33.630) infecções ativas. Em todo o período, o total de infecções acumuladas alcançaria 30,2% (IQR: 19,9% a 36,7%) da população do DF e com uma letalidade de 0,64% (IQR: 0,44% a 0,90%), seriam esperados até 5.500 (IQR: 3.166 a 9.181) óbitos.

CENÁRIO C: Perfil de propagação com a adesão observada no nível de distanciamento social

Seguindo a proposta metodológica descrita para o cenário, a taxa de contatos efetivos seguiu a variação dinâmica do nível de isolamento registrado até a data de 23/05/2020. A partir de 24/05/2020, considera-se a manutenção do nível de isolamento médio de 42,97%, conforme os valores registrados nos últimos 10 dias disponíveis¹⁷. Com isso, projeta-se que a queda observada do nível de distanciamento possa propiciar um pico de até 4.311 (IC50%: 3.181 a 5.840) internações em UTI na data provável de 15/08/2020 (Figura 3).

Dentro deste cenário, para que ao longo de todo o período de análise não haja uma demanda por leitos de UTI acima do total de leitos públicos e privados cadastrados, seria necessário garantir um nível médio de isolamento de pelo menos 58%, o que geraria um pico de demanda de aproximadamente 1.000 internações na data de 13/09/2020. Por outro lado, a interrupção completa do distanciamento, retornando ao nível de isolamento de 30% observado antes da implementação das políticas de distanciamento, poderia

provocar uma demanda com um pico de mais de 8.000 internações em UTI em 31/07/2020.

Ao se elevar o nível de isolamento a uma média de 70% (valor próximo ao máximo obtido na data de 22/03/2020) a partir do dia 24/05/2020, seria possível observar um pico de apenas 306 internações em uti na data de 14/06/2020.

Discussão

A partir de indicadores e dados públicos consultados nesta análise, é possível identificar a adesão ao distanciamento social após a publicação do primeiro decreto de medidas de enfrentamento à COVID-19 no DF. Igualmente, relacionando a evolução temporal do nível de isolamento e a consequente redução progressiva da propagação da doença (R_t), seria possível alcançar valores de referência para o controle de surtos ⁴⁷ ao mesmo tempo postergar e reduzir o pico de internações em UTI para uma estimativa plausível com a capacidade local da rede assistencial.

Diferente do cenário de manutenção do distanciamento social, todos os cenários de ausência de distanciamento social, seja pela não implementação das medidas (Cenário A) ou por sua baixa adesão (Cenário C), mostram uma previsão compatível com o colapso da rede local devido à alta demanda por internações em UTI. Coerente com os achados de análise recente de outros estados brasileiros por pesquisadores do Imperial College London ⁴⁸, mesmo com reduções significativas da propagação de casos, os níveis de isolamento alcançados ainda perpetuam um $R_t > 1$, indicando a manutenção do crescimento epidêmico da COVID-19 no DF.

Apesar desta análise ser restrita ao contexto do DF, ela indica a magnitude do efeito potencial do distanciamento sobre a necessidade de leitos e é improvável que tal

relação, mesmo que em magnitude diferente, não possa ser generalizada para outros contextos. Os resultados são também consistentes com outras iniciativas de análise do distanciamento social^{9–11,49}, incluindo contextos nacionais, como a recente análise dos efeitos positivos do distanciamento social e da redução de fluxo intermunicipal no controle da COVID-19 na Bahia⁵⁰. Segundo os autores, as análises com os dados até então disponíveis, sugeriam fortemente que estas medidas conseguiram suavizar a curva da epidemia na região.

O modelo aqui adotado segue as linhas metodológicas compatíveis com a dinâmica populacional de infecções^{30,31} e foi alimentado com parâmetros locais na medida do possível, incluindo o ajuste da taxa de infecção e letalidade para a estrutura etária local. Adicionalmente, buscou-se o uso transparente das evidências disponíveis e a condução robusta das incertezas paramétricas por meio de simulações de MC^{38,39}. Como demonstrado na presente análise do DF, o acompanhamento de indicadores dinâmicos de isolamento e propagação de infecção, como a estimativa do R_t , acompanhados de sua incerteza, se apresenta como uma estratégia eficiente e pragmática de monitoramento das políticas de enfrentamento à COVID-19^{51,52}.

Limitações

Apesar dos modelos compartimentais em nível de valor esperado conseguirem representar o comportamento médio de epidemias nas populações, não são capazes de representar as histórias individuais³¹. Da mesma forma, a estimativa dos valores dinâmicos das taxas de contatos efetivos é discutida em abordagens variadas na literatura e com impactos potenciais nos resultados de acordo com o método de cálculo^{33,53–55}. Embora considerados os ajustes em relação à estrutura etária local e calibração com base nos registros de internações disponíveis, não foram considerados outros fatores que

podem interferir nos cenários de projeção, como comorbidades relacionadas à maior gravidade da progressão da doença, incluindo doenças cardiovasculares, respiratórias e endócrinas⁵⁶⁻⁵⁹.

Por fim, ressalta-se que os dados de leitos cadastrados aqui apresentados também devem ser interpretados com atenção na referência das metas de redução do impacto sobre a rede hospitalar. Isso, porque não consideram as taxas reais de ocupação por outras condições clínicas e os leitos adicionais que já têm sido implementados pelas autoridades de saúde⁶⁰. Entretanto, mesmo com suas limitações, a análise aqui relatada reforça as conclusões sobre o efeito positivo das medidas de distanciamento social para a 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 considerem o monitoramento diário de indicadores de distanciamento, disseminação da doença e da disponibilidade de leitos hospitalares no planejamento e implementação das políticas públicas de enfrentamento à COVID-19.

Contribuição dos autores

IZ, MS e DA discutiram e construíram o desenho inicial do estudo. IZ, MS e JB trabalharam na coleta de dados e concepção do modelo. IZ implementou o modelo, conduziu as simulações e analisou os principais resultados. Todos os autores contribuíram igualmente para a discussão e avaliação dos resultados finais.

Referências

1. Mohammadi M, Meskini M, do Nascimento Pinto AL. 2019 Novel coronavirus (COVID-19) overview. *J Public Health (Bangkok)*. 19 de abril de 2020;

2. Governo do Distrito Federal. Secretaria de Saúde. Boletins Informativos DIVEP/CIEVES (COE). Boletins Informativos sobre Coronavírus (COVID-19). Brasília: GDF; 2020.
3. Brasil. Ministério da Saúde. Painel Coronavírus [Internet]. COVID19. 2020. Available at: <https://covid.saude.gov.br/>
4. Cucinotta D, Vanelli M. WHO Declares COVID-19 a Pandemic. *Acta Biomed.* 2020;91(1):157–60.
5. Scott D. 4 lessons the US should learn from Italy’s coronavirus mistakes. *Vox.* 29 de março de 2020;
6. Rothan HA, Byrareddy SN. The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak. *J Autoimmun.* maio de 2020;109:102433.
7. Wu Z, McGoogan JM. Characteristics of and Important Lessons From the Coronavirus Disease 2019 (COVID-19) Outbreak in China. *JAMA.* 7 de abril de 2020;323(13):1239.
8. 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. 2020.
9. Wilder-Smith A, Freedman DO. Isolation, quarantine, social distancing and community containment: pivotal role for old-style public health measures in the novel coronavirus (2019-nCoV) outbreak. *J Travel Med.* 13 de março de 2020;27(2).
10. Sen-Crowe B, McKenney M, Elkbuli A. Social distancing during the COVID-19 pandemic: Staying home save lives. *Am J Emerg Med.* abril de 2020;

11. 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 Heal.* março de 2020;
12. Rede CoVida. Painel Rede CoVida [Internet]. 2020. Available at: <https://painel.covid19br.org/>
13. OPAS, MS/SVS, UnB/LAPPIS, UnB/NMT, UnB/FC, Butantã, et al. Pressão hospitalar por COVID-19 [Internet]. 2020. Available at: <https://covid-calc.org/>
14. COVID-19 BRASIL. Monitoramento e análises da situação do Coronavírus no Brasil [Internet]. 2020. Available at: <https://ciis.fmrp.usp.br/covid19/>
15. Penn University. CHIME model: Discrete-time SIR modeling of infections/recovery [Internet]. Available at: <https://code-for-philly.gitbook.io/chime/what-is-chime/sir-modeling>
16. Hill A. Modeling COVID-19 Spread vs Healthcare Capacity [Internet]. 2020. Available at: <https://alhill.shinyapps.io/COVID19seir/>
17. Inloco. Mapa Brasileiro da COVID-19 [Internet]. 2020 [citado 27 de abril de 2020]. Available at: <https://www.inloco.com.br/pt/covid-19>
18. Philips B. Coronavirus 10-day forecast. Melbourne: University of Melbourne; 2020.
19. Brasil. Presidência da República. Casa Civil. Avaliação de políticas públicas : guia prático de análise ex post. Brasília: Casa Civil da Presidência da República; 2018. 301 p.
20. Secchi L. Análise de Políticas Públicas - Diagnóstico de Problemas,

- Recomendação de Soluções. São Paulo: Cengage Learning; 2017.
21. Jannuzzi P de M. Indicadores Sociais no Brasil: conceitos, fonte de dados e aplicações. 6º ed. Campinas: Alinea; 2017. 196 p.
 22. 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. 2020.
 23. 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. Brasília: DODF; 2020.
 24. Governo do Distrito Federal. DECRETO Nº 40.520, DE 14 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. Brasília: DODF; 2020.
 25. Governo do Distrito Federal. DECRETO Nº 40.583, DE 1º DE ABRIL DE 2020. Dispõe sobre as medidas para enfrentamento da emergência de saúde pública de importância internacional decorrente do novo coronavírus. Brasília: DODF; 2020.
 26. Agência Brasília. Testagem para Covid-19 na população começa nesta terça-feira (21) [Internet]. 2020. Available at:
<https://www.agenciabrasilia.df.gov.br/2020/04/20/testagem-para-covid-19-na-populacao-comeca-nesta-terca-feira-21/>

27. Agência Brasília. Primeiro dia de testagem em massa detecta 46 pacientes com a Covid-19 [Internet]. 2020. Available at:
<https://www.agenciabrasilia.df.gov.br/2020/04/21/primeiro-dia-de-testagem-em-massa-detecta-46-pacientes-com-a-covid-19/>
28. Ministério da Saúde. Cadastro Nacional dos Estabelecimentos de Saúde do Brasil - CNES. 2020.
29. Brasil. Ministério da Saúde. Secretaria de Ciência Tecnologia e Insumos Estratégicos. Departamento de Ciência e Tecnologia. Diretrizes metodológicas: Diretriz de Avaliação Econômica. 2014. 132 p.
30. Vynnycky E, White RG, Fine P. An introduction to infectious disease modelling. Oxford: Oxford University Press; 2010.
31. Soárez PC de, Soares MO, Novaes HMD. Modelos de decisão para avaliações econômicas de tecnologias em saúde. *Cien Saude Colet*. outubro de 2014;19(10):4209–22.
32. Rocha Filho TM, dos 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*. 2020;
33. 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*. 2020;5:293–308.
34. Li R, Pei S, Chen B, Song Y, Zhang T, Yang W, et al. Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (SARS-CoV-2). *Science* (80-). 1 de maio de 2020;368(6490):489–93.

35. Ota M. Will we see protection or reinfection in COVID-19? *Nat Rev Immunol*. 17 de abril de 2020;
36. WHO. “Immunity passports” in the context of COVID-19 [Internet]. 2020. Available at: <https://www.who.int/news-room/commentaries/detail/immunity-passports-in-the-context-of-covid-19>
37. Eufrásio J. Adiada para 11 de maio, reabertura do comércio no DF dependerá da Justiça. *Correio Braziliense*. 20 de abril de 2020;
38. Briggs AH, Weinstein MC, Fenwick EAL, Karnon J, Sculpher MJ, Paltiel AD. Model Parameter Estimation and Uncertainty: A Report of the ISPOR-SMDM Modeling Good Research Practices Task Force-6. *Value Heal*. setembro de 2012;15(6):835–42.
39. Briggs A, Claxton K, Sculpher M. *Decision Modelling for Health Economic Evaluation*. Oxford: Oxford University Press; 2011. 256 p.
40. Jung K, Lee J, Gupta V, Cho G. Comparison of Bootstrap Confidence Interval Methods for GSCA Using a Monte Carlo Simulation. *Front Psychol*. 11 de outubro de 2019;10.
41. Buckland ST. Monte Carlo Methods For Confidence Interval Estimation Using The Bootstrap Technique. *J Appl Stat*. 28 de janeiro de 1983;10(2):194–212.
42. McMurray A, Pearson T, Casarim F. *Guidance on Applying the Monte Carlo Approach*. Winrock International; 2017.
43. Pinder JP. Chapter 8 - Simulation accuracy: central limit theorem and sampling. In: Pinder JP, organizador. *Introduction to Business Analytics using Simulation*. Boston: Academic Press; 2017. p. 197–257.

44. Hallak R, Pereira Filho AJ. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de advecção e assimilação de dados. *Rev Bras Meteorol.* 2011;26(4):591–608.
45. Kemmer G, Keller S. Nonlinear least-squares data fitting in Excel spreadsheets. *Nat Protoc.* 28 de fevereiro de 2010;5(2):267–81.
46. Zimmermann I. Modelo de Projeção da Demanda por leitos de UTI por COVID-19 [Demand for critical care beds during COVID-19 Model] [Internet]. Mendeley Data. 2020. Available at: <http://dx.doi.org/10.17632/bypzkmwnrv>
47. van den Driessche P. Reproduction numbers of infectious disease models. *Infect Dis Model.* agosto de 2017;2(3):288–303.
48. Mellan TA, Hoeltgebaum HH, Mishra S, Whittaker C, Schnekenberg RP, Gandy A. Report 21: Estimating COVID-19 cases and reproduction number in Brazil. Imperial College London; 2020. p. 24.
49. Fong MW, Gao H, Wong JY, Xiao J, Shiu EYC, Ryu S, et al. Nonpharmaceutical Measures for Pandemic Influenza in Nonhealthcare Settings—Social Distancing Measures. *Emerg Infect Dis.* maio de 2020;26(5):976–84.
50. Rede CoVida. Os impactos das medidas de distanciamento social e redução de fluxo intermunicipal na Bahia. *Bol CoVida.* 2020;1(2):19.
51. Yuan J, Li M, Lv G, Lu ZK. Monitoring Transmissibility and Mortality of COVID-19 in Europe. *Int J Infect Dis.* março de 2020;
52. 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. 2020;
53. Kirkeby C, Halasa T, Gussmann M, Toft N, Græsbøll K. Methods for estimating disease transmission rates: Evaluating the precision of Poisson regression and two novel methods. *Sci Rep*. 25 de dezembro de 2017;7(1):9496.
 54. Wearing HJ, Rohani P, Keeling MJ. Appropriate Models for the Management of Infectious Diseases. Ellner SP, organizador. *PLoS Med*. 26 de julho de 2005;2(7):e174.
 55. Chowell G, Sattenspiel L, Bansal S, Viboud C. Mathematical models to characterize early epidemic growth: A review. *Phys Life Rev*. setembro de 2016;18:66–97.
 56. CDC. Groups at Higher Risk for Severe Illness [Internet]. *Coronavirus Disease 2019 (COVID-19)*. 2020. Available at: <https://www.cdc.gov/coronavirus/2019-ncov/need-extra-precautions/groups-at-higher-risk.html>
 57. Jordan RE, Adab P, Cheng KK. Covid-19: risk factors for severe disease and death. *BMJ*. 26 de março de 2020;m1198.
 58. 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*. 6 de abril de 2020;
 59. 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*. 19 de abril de 2020;2020:1–17.

60. Brasil. Ministério da Saúde. Governo Federal inicia construção do primeiro hospital de campanha em Águas Lindas (GO) [Internet]. 2020. Available at: <https://www.saude.gov.br/noticias/agencia-saude/46680-governo-federal-inicia-construcao-do-primeiro-hospital-de-campanha-em-aguas-lindas-go>
61. 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.* 2020;
62. 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.* 17 de fevereiro de 2020;9(2):538.
63. 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.* março de 2020;

SUPLEMENTO

Transições e equações

Uma vez infectado, o indivíduo se torna exposto por um período de latência, por sua vez, 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 a hospitalização (I_2 ou I_3) ou é removido (R) de circulação por quarentena. A hospitalização foi prevista para os indivíduos que ocorre a partir do quadro leve (I_1) evoluem para um quadro grave (I_2) ou crítico (I_3). Coerente com o seguimento de pacientes com Covid-19 (Wu e McGoogan, 2020), aos pacientes que progridem para o quadro crítico, é prevista a transição para o óbito de acordo com uma taxa de letalidade específica da doença (μ). Em cada um dos compartimentos de indivíduos hospitalizados, é também prevista a possibilidade de remoção do modelo de acordo com a duração da hospitalização (γ^{-1}).

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

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

$$\delta = \frac{ifr}{(f_{hosp} f_{uti})} \quad (2)$$

$$\mu = \delta \frac{1}{(\text{tempo até a morte} - \text{tempo até isolamento ou hospitalização} - \text{tempo em leito regular})} \quad (3)$$

$$\gamma_1 = f_{hosp}(\text{tempo até isolamento ou hospitalização})^{-1} \quad (4)$$

$$\gamma_2 = (1 - f_{uti})(\text{tempo em leito regular})^{-1} \quad (5)$$

$$\gamma_3 = (1 - \delta)(\text{tempo em leito de uti})^{-1} \quad (6)$$

$$p_1 = (\text{tempo até isolamento ou hospitalização})^{-1} - \gamma_1 \quad (7)$$

$$p_2 = f_{uti}(\text{tempo em leito regular})^{-1} \gamma_1 \quad (8)$$

Relação entre o distanciamento social e o coeficiente transmissão

Com o intuito de simular a propagação da doença mediante os efeitos do distanciamento social, adotou-se o cálculo da taxa efetiva de contatos (β) a partir das estimativas epidêmicas e de isolamento social disponíveis (Chowell *et al.*, 2016; Eikenberry *et al.*, 2020; Kirkeby *et al.*, 2017; Wallinga e Lipsitch, 2007; Wearing, Rohani e Keeling, 2005). Para tanto, considera-se aqui a relação dinâmica de que taxa efetiva de contatos (β) em cada instante segue uma 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 DF são imputados no modelo como o complemento do fator c . Da mesma forma, semelhante ao proposto por Eikenberry *et al.* (2020)(Eikenberry *et al.*, 2020), 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 DF no período de 22/03/2020 a 21/05/2020.

Tendo-se a taxa de contatos efetivos β , foi também calculado 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. Coerente com abordagens metodológicas prévias (Driessche, van den, 2017)(Wearing, Rohani e Keeling, 2005), o número de reprodução instantâneo (R_t) considera as taxas específicas de entrada e saída do compartimento infeccioso por meio da equação 9.

$$R_t = \frac{\beta(t)S(t)}{(p_1 + \gamma_1)} \quad (9)$$

Tabela S1. Taxas de infecção, hospitalização e letalidade esperadas de acordo com a estrutura etária do Distrito Federal, Brasil

Faixa Etária	Habitantes	Frequência	Taxa de infecção (por 10 mil habitantes)	Taxa de hospitalização de infectados	Taxa de letalidade de infectados
0 a 9	419.157	13,00%	0,36	0,00%	0,00%
10 a 19	450.663	13,98%	13,73	0,04%	0,01%
20 a 29	594.106	18,43%	14,92	1,04%	0,03%
30 a 39	570.790	17,71%	14,24	3,43%	0,08%
40 a 49	483.968	15,02%	13,99	4,25%	0,16%
50 a 59	336.382	10,44%	15,98	8,16%	0,60%
60 a 69	207.838	6,45%	15,33	11,80%	1,93%
70 a 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%	0,576%

Fonte: Valores estimados a partir de IBGE, 2020 e Verity et al, 2020

Tabela S2. Série histórica de internações em UTI, número de óbitos e nível de isolamento social

Data	Internações em UTI	Óbitos acumulados	Nível de isolamento
01/03/2020	0	0	0,4090
02/03/2020	0	0	0,2740
03/03/2020	0	0	0,2810
04/03/2020	0	0	0,2930
05/03/2020	0	0	0,2960
06/03/2020	0	0	0,2900
07/03/2020	0	0	0,3180
08/03/2020	0	0	0,3980
09/03/2020	0	0	0,2891
10/03/2020	0	0	0,2880
11/03/2020	0	0	0,2770
12/03/2020	0	0	0,3220
13/03/2020	0	0	0,3190
14/03/2020	0	0	0,3650
15/03/2020	0	0	0,4260
16/03/2020	0	0	0,3430
17/03/2020	0	0	0,3430
18/03/2020	0	0	0,3670
19/03/2020	0	0	0,3990
20/03/2020	0	0	0,4430

21/03/2020	0	0	0,5670
22/03/2020	1	0	0,6560
23/03/2020	1	1	0,5590
24/03/2020	1	1	0,6110
25/03/2020	6	1	0,5710
26/03/2020	6	1	0,5610
27/03/2020	8	1	0,5340
28/03/2020	13	1	0,5700
29/03/2020	19	2	0,5990
30/03/2020	20	2	0,5761
31/03/2020	30	3	0,5010
01/04/2020	30	4	0,4730
02/04/2020	41	6	0,4980
03/04/2020	40	9	0,4870
04/04/2020	38	10	0,5100
05/04/2020	41	12	0,5770
06/04/2020	37	12	0,4890
07/04/2020	40	12	0,4720
08/04/2020	42	13	0,4640
09/04/2020	35	14	0,4470
10/04/2020	33	14	0,5480
11/04/2020	32	14	0,4760
12/04/2020	33	16	0,5370
13/04/2020	30	17	0,4690
14/04/2020	28	19	0,4680
15/04/2020	30	22	0,4750
16/04/2020	29	22	0,4570
17/04/2020	25	24	0,4350
18/04/2020	26	24	0,4780
19/04/2020	28	24	0,5420
20/04/2020	28	24	0,4630
21/04/2020	29	24	0,5360
22/04/2020	30	25	0,4500
23/04/2020	30	26	0,4580
24/04/2020	32	26	0,4330
25/04/2020	34	27	0,4610
26/04/2020	34	27	0,5280
27/04/2020	35	28	0,4450
28/04/2020	36	28	0,4410
29/04/2020	38	28	0,4300
30/04/2020	38	30	0,4210
01/05/2020	43	31	0,4930
02/05/2020	45	32	0,4440
03/05/2020	49	33	0,4960
04/05/2020	59	33	0,4370
05/05/2020	56	34	0,4240

06/05/2020	60	35	0,4220
07/05/2020	60	35	0,4290
08/05/2020	64	37	0,4010
09/05/2020	66	39	0,4250
10/05/2020	72	42	0,4540
11/05/2020	78	44	0,4290
12/05/2020	87	46	0,4280
13/05/2020	92	48	0,4210
14/05/2020	94	51	0,4190
15/05/2020	86	55	0,4120
16/05/2020	84	56	0,4472
17/05/2020	116	59	0,5176
18/05/2020	121	66	0,4248
19/05/2020	125	72	0,4205
20/05/2020	142	78	0,4120
21/05/2020	138	84	0,4121

Fonte: Elaborado a partir dos Boletins Epidemiológicos locais e da base pública da Inloco, 2020




Figura S1. Ilustração das funções de distribuição de probabilidade dos principais parâmetros do modelo. Fonte: Elaboração própria

Referências

CHOWELL, G. *et al.* Mathematical models to characterize early epidemic growth: A review. **Physics of Life Reviews**, v. 18, p. 66–97, set. 2016.

DRIESSCHE, P. VAN DEN. Reproduction numbers of infectious disease models. **Infectious Disease Modelling**, v. 2, n. 3, p. 288–303, ago. 2017.

EIKENBERRY, S. E. *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. **Infectious Disease Modelling**, v. 5, p. 293–308, 2020.

KIRKEBY, C. *et al.* Methods for estimating disease transmission rates: Evaluating the precision of Poisson regression and two novel methods. **Scientific Reports**, v. 7, n. 1, p. 9496, 25 dez. 2017.

WALLINGA, J.; LIPSITCH, M. How generation intervals shape the relationship between growth rates and reproductive numbers. **Proceedings of the Royal Society B: Biological Sciences**, v. 274, n. 1609, p. 599–604, 22 fev. 2007.

WEARING, H. J.; ROHANI, P.; KEELING, M. J. Appropriate Models for the Management of Infectious Diseases. **PLoS Medicine**, v. 2, n. 7, p. e174, 26 jul. 2005.

WU, Z.; MCGOOGAN, J. M. Characteristics of and Important Lessons From the Coronavirus Disease 2019 (COVID-19) Outbreak in China. **JAMA**, v. 323, n. 13, p. 1239, 7 abr. 2020.