

---

# CARACTERÍSTICAS DA PANDEMIA DO COVID-19 E IMPACTO DAS POLÍTICAS DE ISOLAMENTO NO BRASIL, MINAS GERAIS E JUIZ DE FORA

---

**Ruy Freitas Reis<sup>1</sup>, Bárbara de Melo Quintela<sup>1,2</sup>, Joventino de Oliveira Campos<sup>3,4</sup>, Johnny Moreira Gomes<sup>3</sup>, Lara Turetta Pompei<sup>5</sup>, Bernardo Martins Rocha<sup>1,3</sup>, Marcelo Lobosco<sup>1,3</sup>, Rodrigo Weber dos Santos<sup>1,3</sup>**

<sup>1</sup> Departamento de Ciência da Computação, Universidade Federal de Juiz de Fora

<sup>2</sup> Department of Industrial Engineering, Alma Mater Studiorum - University of Bologna (IT)

<sup>3</sup> Programa de Pós-Graduação em Modelagem Computacional, Universidade Federal de Juiz de Fora

<sup>4</sup> Centro Federal de Educação Tecnológica de Minas Gerais, Leopoldina

<sup>5</sup> Graduanda em Engenharia Elétrica, Universidade Federal de Juiz de Fora

ruyfreitas@ice.ufjf.br, barbara@ice.ufjf.br, joventino@cefetmg.br,  
johnny.gomes@ufjf.edu.br, pompei.lara@engenharia.ufjf.br, bernardomartinsrocha@ice.ufjf.br,  
marcelo.lobosco@ice.ufjf.br, rodrigo.weber@ufjf.edu.br

30 de Março de 2020

## 1 Introdução

Em 31 de Dezembro de 2019 a China reportou um surto de pneumonia em que o agente causador foi identificado em 7 de Janeiro como SARS-CoV-2. A doença passou a ser chamada de COVID-19 (abreviação de *CO*rona*VI*rus *D*isease *2019*) pela Organização Mundial de Saúde (OMS) [20, 29]. Após um mês da notificação inicial, a OMS já declarava a COVID-19 como uma emergência de saúde pública e em 11 de Março de 2020 como uma pandemia [26].

Até o momento da elaboração do presente estudo, haviam 663.127 pessoas infectadas e 30.861 mortes em 195 países [28]. O primeiro caso da infecção reportado no Brasil ocorreu no dia 26 de Fevereiro de 2020. De acordo com o Informe Epidemiológico Coronavírus do dia 28 de Março de 2020 da Secretaria de Estado de Saúde de Minas Gerais, Juiz de Fora possui 11 casos dos 205 confirmados no estado. O primeiro caso foi confirmado na cidade no dia 14 de Março [19]. Após um mês do primeiro caso confirmado no Brasil, já foram contabilizados 3.904 casos e 114 mortes [13].

O maior número de casos confirmados de COVID-19 no estado de Minas Gerais se concentra na capital do estado, Belo Horizonte, que apresentava 129 casos confirmados no dia 28/03/2020 (Figura 1). Até o momento do fechamento do presente estudo, as demais cidades apresentavam números oficiais inferiores a 20 casos. A cidade de Nova Lima apresenta 16 casos confirmados e Juiz de Fora, 11 casos confirmados.

Deve-se reforçar que devido a demora para a obtenção dos resultados dos exames, os números reportados de casos confirmados refletem a situação com alguns dias de atraso. Além disso, observa-se que o número acumulado de notificações de casos suspeitos no estado de MG é superior a 20 mil (Figura 2).

Para controlar a transmissão entre as pessoas, as principais ferramentas de saúde pública disponíveis são isolamento e quarentena, distanciamento social e medidas de contenção comunitárias [25]. Mesmo que essas ferramentas sejam difíceis de implementar, principalmente por períodos de tempo indeterminados, há indícios de que auxiliam na redução do pico de incidência e, conseqüentemente, reduzem o impacto nos serviços de saúde [12, 24].

Uma ferramenta que tem sido amplamente utilizada para mostrar os efeitos de diferentes políticas de contenção é a modelagem matemática [7]. Através do uso de modelos matemáticos é possível representar as dinâmicas das populações

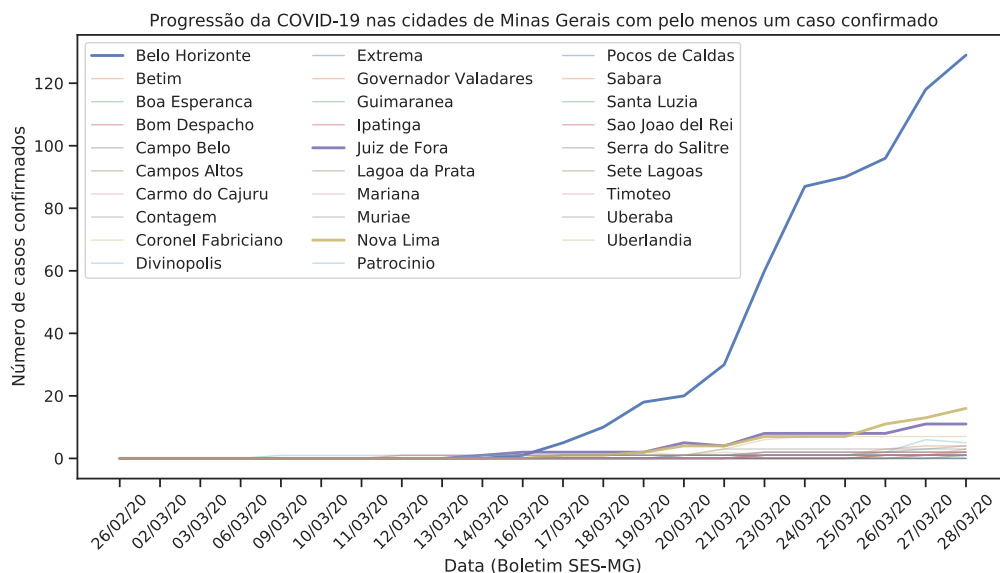


Figura 1: Progressão de casos confirmados ao longo do tempo segundo informes epidemiológicos da Secretaria de Estado de Saúde de Minas Gerais. Destaque para as três cidades que apresentam o maior número de casos até o momento, Belo Horizonte, Nova Lima e Juiz de Fora.

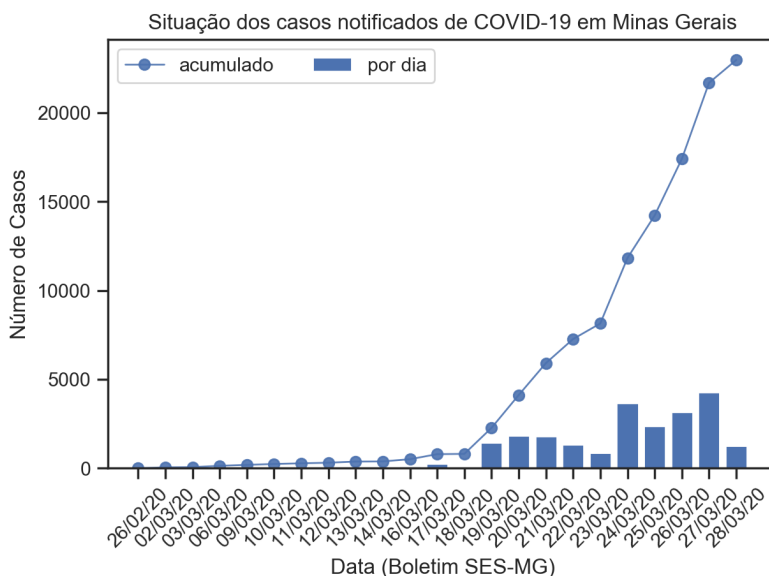


Figura 2: Número total de casos notificados a Secretaria de Estado de Saúde de Minas Gerais, incluindo casos que foram confirmados e os que estavam sob análise. São exibidos os valores de novas notificações por dia e o total acumulado.

e suas interações e realizar previsões, sendo possível prever com confiança o número de casos e, conseqüentemente, o impacto no sistema de saúde de acordo com as políticas adotadas [4, 8, 17, 18].

O objetivo desse estudo preliminar baseado em modelos matemáticos e computacionais é auxiliar na resposta das seguintes perguntas de interesse para a cidade de Juiz de Fora:

1. Quais são as características particulares da pandemia no Brasil, Minas Gerais e Juiz de Fora?
2. Qual o impacto das políticas de contenção de transmissão?

Para isso, foi realizado um estudo da pandemia em diferentes países, para estimar importantes características, como taxa de infecção, efeito do isolamento intra-municipal e internacional/interestadual, subnotificação dos infectados e taxa de mortalidade. Em seguida, são apresentadas as previsões para a dinâmica da pandemia COVID-19 no país, estado de Minas Gerais e cidade de Juiz de Fora.

## 2 Material e Métodos

### 2.1 Modelo matemático

Com o intuito de responder às questões levantadas optou-se por um modelo matemático-computacional do tipo SIR [11, 16, 22, 23] onde algumas modificações específicas foram incluídas (detalhes no [Apêndice](#)). As variáveis  $S$ ,  $I$ ,  $R$ ,  $O$  e  $I_n$  variam ao longo do tempo e representam o número de indivíduos de uma população, com um total de tamanho  $N$ , que estão suscetíveis, infectados, recuperados, que foram a óbitos e o número de indivíduos notificados como infectados, respectivamente (Figura 3).

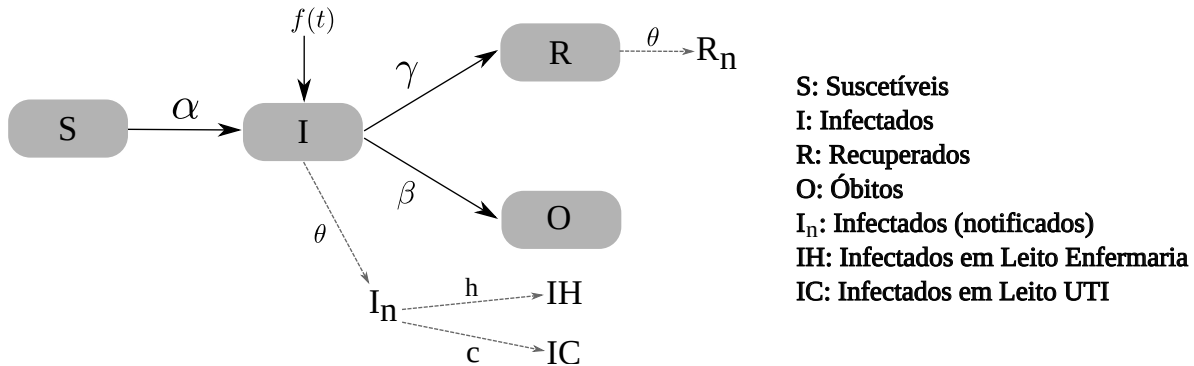


Figura 3: Diagrama de fluxo do modelo matemático do COVID-19 que considera a demanda por leitos para tratamento. Este diagrama apresenta a proposta de uma modificação do modelo SIR. Além das variáveis  $S$  (suscetível),  $I$  (infectado) e  $R$  (recuperado), foram adicionadas as variáveis  $O$  (óbito),  $I_n$  (infectado que foi notificado),  $R_n$  (recuperado que foi notificado) e  $IH$  (infectado ocupante de leito hospitalar simples),  $IC$  (infectado ocupante de leito em UTI). A função  $f(t)$  modela a entrada de pessoas infectadas vindas de outras regiões, estados ou países. Além disso,  $\alpha$  representa taxa de transição de  $S$  para  $I$ ,  $\gamma$  representa taxa de transição de  $I$  para  $R$ ,  $\beta$  representa taxa de transição de  $I$  para  $O$ ,  $\theta$  representa a fração de casos notificados,  $c$  a fração de casos notificados que necessitam de tratamento hospitalar intensivo e  $h$  a fração de casos notificados que necessitam de tratamento hospitalar simples.

Para estimar como varia ao longo do tempo os números de leitos para casos com necessidade de hospitalização (infectado hospitalizado  $IH$ ), e de atendimento intensivo (infectado em situação crítica  $IC$ ), assume-se que esses valores são proporcionais à população infectada notificada ( $I_n$ ) e ao percentual dessa população que apresenta complicações severas ( $c$ ) ou graves ( $h$ ), respectivamente. Mais detalhes sobre esse modelo e seus parâmetros podem ser encontrados no [Apêndice](#).

A seguir apresentamos as principais informações sobre os parâmetros do modelo:

- $\frac{\alpha}{N} = a(t)b/N$  representa a taxa com a qual um indivíduo suscetível se torna infectado; sendo que  $a(t)$  representa a probabilidade de contato e  $b$  é a taxa de infecção. Como a probabilidade de contato  $a(t)$  pode variar dependendo da adoção de políticas de contenção do espalhamento do vírus, este é representado como uma função do tempo (Equação (6) no [Apêndice](#)).

Essa é uma abordagem simples que assume que as políticas de contenção começam a ser adotadas em  $t_i$ , e no tempo final ( $t_f$ ) a mesma consegue reduzir a probabilidade de contato em  $r\%$ . Um exemplo de função  $a(t)$  é apresentado na Figura 4. Nesse exemplo, apresentamos duas fases. Uma fase inicial onde a política de contenção é implementada entre os tempos  $t_i$  e  $t_f$ , seguida por uma segunda fase de flexibilização da política de contenção, entre os tempos  $t_{2i}$  e  $t_{2f}$ .

- $\tau_o = \tau_1 + \tau_2$ , onde  $\tau_1$  é o tempo de incubação do vírus e  $\tau_2$  é o tempo entre o aparecimento dos primeiros sintomas e o óbito. De forma similar,  $\tau_r = \tau_1 + \tau_3$ , onde  $\tau_3$  é o tempo entre o aparecimento dos primeiros sintomas e a recuperação.




Figura 4: Exemplo de função  $a(t)$  que modela a modificação da probabilidade de contato entre pessoas ao longo do tempo. Nesse exemplo, apresentamos duas fases. Na fase inicial, a política de contenção é implementada entre os tempos  $t_i$  e  $t_f$ , e reduz a probabilidade de contato por um fator  $r$ . Essa fase é seguida por uma segunda fase de flexibilização da política de contenção, entre os tempos  $t2_i$  e  $t2_f$ , onde durante esta fase  $a(t)$  aumenta para 50% de  $r$ .

- $\beta = m(1/\tau_o)$  representa a taxa de mortalidade dos indivíduos infectados, onde  $m$  é a taxa de mortalidade e  $\tau_o$  o número de dias da infecção até o óbito.
- $\gamma$  representa a taxa com que indivíduos infectados se recuperam,  $\gamma = (1 - m)(1/\tau_r)$ , onde  $\tau_r$  é o número de dias da infecção até a recuperação.
- $f(t) = eP(t)$  é um termo que representa o número de pessoas infectadas que entram na cidade. A hipótese considerada é que pode-se representar esse termo pelo produto de uma função  $P(t)$  do número de pessoas infectadas no mundo por uma taxa  $e$  de movimentação. Essa taxa pode ser modificada para representar as políticas de restrição de mobilidade internacional e interestadual.
- $\theta$  representa o percentual de notificação de infectados.

## 2.2 Ajuste dos parâmetros e propagação de incertezas

Os parâmetros relativos às dinâmicas da COVID-19 foram baseados em dados reportados na literatura disponível até o momento e relatos da epidemia em outras localidades com estágios mais avançados [5, 9, 13, 19, 23, 28]. Para a calibração dos parâmetros e para os estudos realizados, além dos dados do Brasil, outros dois países com situações distintas com relação a atual pandemia foram escolhidos: a Coreia do Sul e a Itália. Os valores e faixas para os parâmetros do modelo estão apresentados na Tabela A.2, no Apêndice.

O ajuste dos parâmetros foi feito utilizando métodos de otimização bem estabelecidos, tais como o método dos mínimos quadrados e o método da evolução diferencial, ambos implementados na linguagem de programação Python [15, 21].

Os valores dos parâmetros foram estimados com base em dados sobre a epidemia de cada local. A evolução diferencial foi utilizada para estimar cada um dos parâmetros do modelo matemático proposto, respeitando os limites estabelecidos para cada um deles (ver Tabela A.2). Assim, todos os parâmetros do modelo (exceto  $c$  e  $h$ ) foram estimados para cada país, utilizando números atuais de infectados e mortos oficialmente reportados por eles, onde a função objetivo minimizava o erro relativo entre os dados e a resposta do modelo. Separadamente, para o cenário da Itália e Brasil também foram utilizados os dados sobre o número de leitos hospitalares simples e de cuidado intensivo (UTI) para

estimar os parâmetros  $c$  e  $h$ . Não foi possível fazer o mesmo para a Coreia do Sul exclusivamente devido aos autores não terem tido acesso a esses dados. Para o estado de Minas Gerais e a cidade de Juiz de fora, foram utilizados os mesmos parâmetros estimados para o Brasil, exceto  $e$ ,  $r$ ,  $t_i$  e  $t_f$ , pois estas características são diferentes em cada região.

Para a análise de quantificação de incertezas realizada neste trabalho adotou-se o método da expansão polinomial Chaos associados com o método da colocação estocástica [1, 14]. Essa escolha se deve ao fato de que este método é mais eficiente que métodos tradicionais como o método de Monte Carlo [3], e permite calcular momentos estatísticos tais como média, desvio padrão, percentis e intervalo de predição de forma simples, uma vez que o emulador do modelo tenha sido construído. Estas análises foram realizadas com o auxílio da biblioteca Chaospy [6].

### 3 Resultados e discussões

#### 3.1 Caracterização da pandemia COVID-19 em diferentes países

Os parâmetros dos modelos foram ajustados para três países distintos, Itália, Coreia do Sul e Brasil. Após o ajuste dos parâmetros, foi realizada a propagação de incertezas para estimar os piores e melhores cenários possíveis. Para isso foi considerada uma incerteza na estimativa dos parâmetros de 10%. As Figuras 5, 6 e 7 apresentam os resultados para a Itália, Coreia do Sul e Brasil, respectivamente. Deve-se destacar que o mesmo modelo foi utilizado em todos os estudos, apenas ajustando-se os parâmetros referentes a cada país para capturar adequadamente nestes a dinâmica da pandemia COVID-19.

A Itália continua apresentando crescimento tanto do número de infectados como do número de mortos. Para este país, considerando a disponibilidade de dados sobre o número de leitos simples e de leitos em centros (ou unidades) de terapia intensiva (CTI ou UTI), foi possível simular também a dinâmica do uso desses tipos de leitos, como mostra a Figura 5.

No caso da Coreia do Sul, apresentado na Figura 6, nota-se que o modelo representa de forma adequada os dados reportados, mesmo considerando que esse caso já se encontra em fase de decrescimento do número de infectados.

O Brasil ainda está na fase inicial do COVID-19, possuindo números de infectados e de mortes ainda baixos comparados com os outros dois países. Mesmo assim, o modelo também foi capaz de representar a tendência de crescimento dos casos confirmados, como mostra a Figura 7.

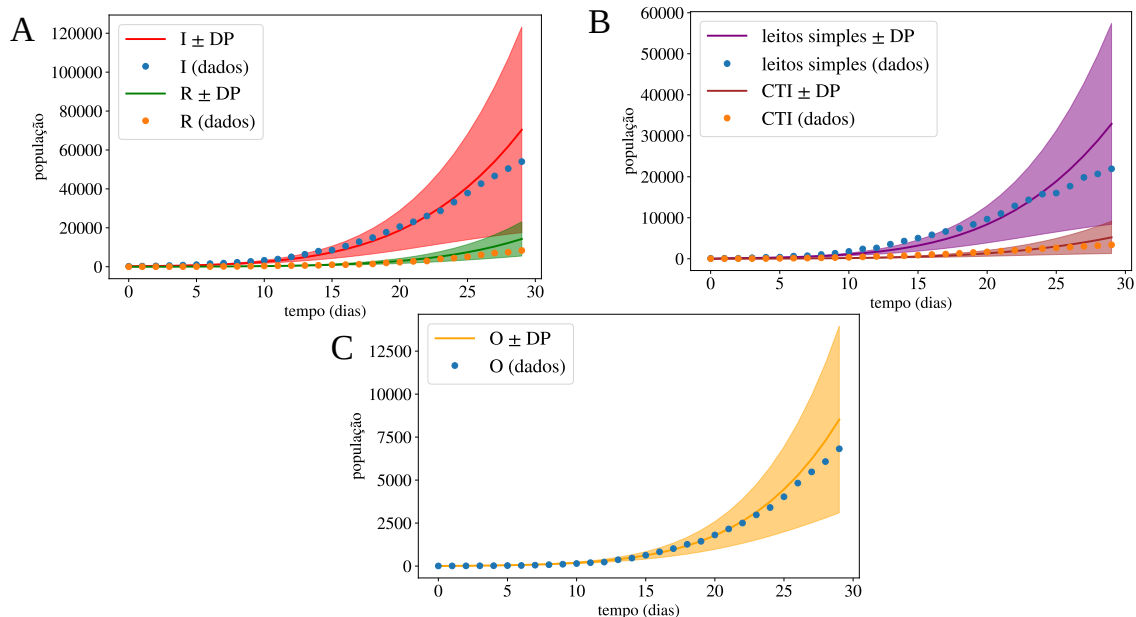


Figura 5: Resultados das simulações para o cenário da Itália. O início da simulação corresponde ao dia 24/02/2020 e o fim ao dia 24/03/2020. (A) Número de pessoas infectadas que foram notificadas ( $I_n$ ) e o número de pessoas recuperadas ( $R$ ) com o passar dos dias. (B) Número de leitos simples e leitos CTI necessários. (C) Número de óbitos ( $O$ ) ao longo dos dias. As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) das quantidades, enquanto os pontos são os dados da literatura [2].

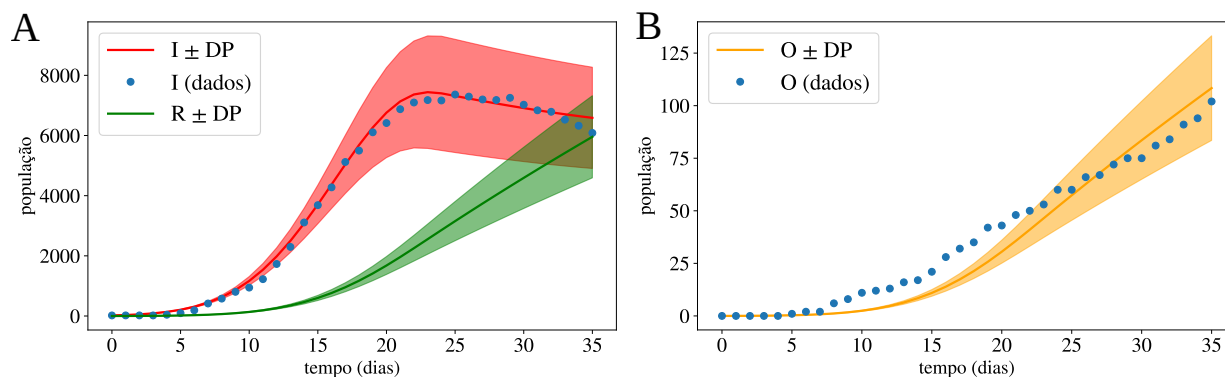


Figura 6: Resultados das simulações para o cenário da Coreia do Sul. O início da simulação corresponde ao dia 15/02/2020 e o fim ao dia 21/03/2020. **(A)** Número de pessoas infectadas que foram notificadas ( $I_n$ ) e o número de pessoas recuperadas (R) com o passar dos dias. **(B)** Número de óbitos (O) ao longo dos dias. As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) das quantidades, enquanto os pontos são os dados da literatura [28].

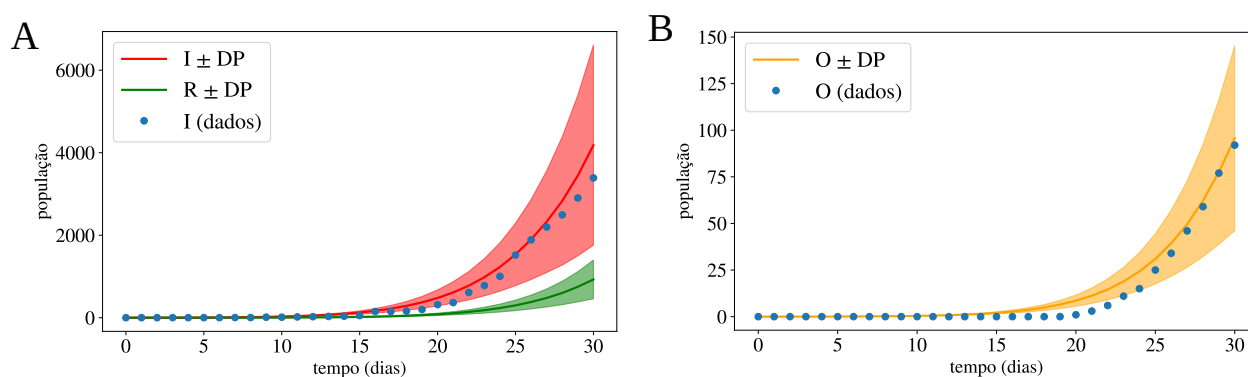


Figura 7: Resultados das simulações para o cenário do Brasil. O início da simulação corresponde ao dia 26/02/2020 e o fim ao dia 27/03/2020. **(A)** Número de pessoas infectadas que foram notificadas ( $I_n$ ) e o número de pessoas recuperadas (R) com o passar dos dias. **(B)** Número de óbitos (O) ao longo dos dias. As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados da literatura [10].

Na Tabela 3.1 apresentamos os resultados do ajuste de parâmetros para os três países considerados neste estudo: Coreia do Sul, Itália e Brasil.

Tabela 1: Caracterização da pandemia Covid-19 em diferentes países

Parâmetro	Significado	Coreia do Sul	Itália	Brasil
$b(\times 10^{-1})$	taxa de transmissão do COVID-19	5.6	2.69	3.81
$m(\%)$	probabilidade de fatalidade	1.41	3.34	1.38
$c(\%)$	porcentagem de casos críticos (UTI)	-	8.50	6.47
$h(\%)$	porcentagem de hospitalizados	-	53.4	6.83
$r(\%)$	redução da taxa de contato	5.7	53.5	58.6
$rb(\times 10^{-9})$	taxa de contágio efetiva	3.19	14.4	22.3
$t_i$	instante inicial da pol. de contenção	0	7	7
$t_f$	instante final da pol. de contenção	23	28	29
$\theta(\%)$	percentual de casos infectados notificados	84.6	8.26	8.12

Como o modelo é do tipo descritivo, ou mecanicista, a análise dos parâmetros permite a identificação de importantes características dos fenômenos. Com relação a pandemia, pode-se destacar a taxa de transmissão,  $b$ , a probabilidade

de óbito,  $m$ , e os percentuais de casos que necessitam de hospitalização em leitos simples,  $h$ , e de casos críticos que necessitam de leitos em UTI,  $c$ . A taxa  $b$  é semelhante entre os três países, com o Brasil apresentando uma taxa entre a da Coreia do Sul e a da Itália. A probabilidade de óbito é em torno de 1.5% para Brasil e Coreia do Sul e mais alta na Itália, 3.3%. Na Itália, 53% dos infectados notificados são hospitalizados em leitos simples, e 8.5% ocupam leitos em UTIs (Unidades de Terapia Intensiva). Os números no Brasil são bem diferentes, cerca de 7% de demanda por hospitalização em leitos simples, e 6% em UTIs. Esta diferença pode ser justificada por diferenças nas pirâmides demográficas, ou mesmo pelo Brasil ainda estar no início da pandemia.

Com relação ao manejo político-estratégico adotado pelos países, também observam-se diferenças interessantes. A Coreia do Sul adotou uma estratégia de isolamento bastante eficaz, reduzindo a transmissão do vírus,  $b$ , para 5%,  $r$ , de seu valor inicial. Além disso, o país o fez rapidamente, começando no primeiro dia,  $t_i = 0$  e terminando a implementação das estratégias de isolamento no dia  $t_f = 23$ . Já Brasil e Itália reduziram  $b$  apenas para metade de seu valor inicial,  $r$  em torno de 50%. Além disso, a reação foi mais lenta, com  $t_i = 7$  e  $t_f = 29$ . Finalmente, observamos que a notificação de casos infectados na Coreia do Sul é alta, em torno de 85%, enquanto no Brasil e na Itália as notificações tem percentual bem baixo, em torno de 8%. Assim, estima-se que o número de infectados nesses últimos dois países é superior a  $12 \times$  o número de casos notificados. Esta subnotificação dificulta o manejo da pandemia pois acrescenta maiores incertezas quanto a dinâmica da mesma.

### 3.2 Previsões para o Brasil, Minas Gerais e Juiz de Fora

Com os modelos ajustados, pode-se usá-los para fazer previsões quanto a evolução da pandemia para dias futuros. Além disso, diferentes cenários podem ser simulados, onde aqui tem-se em especial o objetivo de avaliar o impacto de diferentes políticas de isolamento.

Porém, antes de fazer as previsões, foi avaliado, usando dados da Coreia do Sul e da Itália, qual o grau de confiança das previsões. Como resultado, observou-se que ao usar apenas os primeiros 20 dias de dados para ajustar os modelos, as simulações possuem credibilidade para previsão de 10 dias futuros. Até 10 dias, as previsões se encontram dentro de um intervalo de confiabilidade de 10% de erro. Além de 10 dias, as previsões são de baixa credibilidade. Isso ocorre, provavelmente, por outros efeitos da dinâmica da pandemia e das ações associadas à política de isolamento não estarem sendo considerados pelo atual modelo. Esses estudos são apresentados no [Apêndice](#) (Figuras 11 e 12). Sendo assim, os próximos resultados foram gerados ajustando os modelos do Brasil, do estado de Minas Gerais (MG) e da cidade de Juiz de Fora (JF) entre os dias 26/02/2020 e 27/03/2020, e usando os simuladores para fazer as previsões até o dia 7 de Abril de 2020.

Na previsão para o caso do Brasil, estima-se para cerca de 30 mil as notificações de infectados (Figura 8). Porém, considerando as incertezas nos parâmetros do modelo, a faixa de infectados notificados está entre 10 mil e 60 mil. Da mesma forma, há um aumento no número de óbitos ao longo do tempo, para uma estimativa de cerca de 800 pessoas, dentro de uma faixa de incerteza de 250 a 1.300 óbitos.

Os parâmetros  $h$  e  $c$  foram estimados para o Brasil usando poucos dados disponíveis. Dessa forma, há uma incerteza adicional com relação a esses parâmetros. Por isso, foram simulados dois cenários para a estimativa da evolução dos leitos simples e de UTI. O painel C da Figura 8 mostra o cenário usando os parâmetros obtidos com os escassos dados do Brasil ( $h = 7\%$ ,  $c = 8\%$ ). Neste cenário, os números de leitos tanto simples como de UTI aumentam para cerca de dois mil cada (observado o intervalo de confiança da previsão). O painel D da Figura 8 mostra o cenário usando os parâmetros obtidos com os dados da Itália ( $h = 53\%$ ,  $c = 8.5\%$ ). Neste cenário, o número de leitos simples aumenta até 15 mil e o número de leitos UTI até 2 mil (observe os intervalos de confiança das previsões na figura).

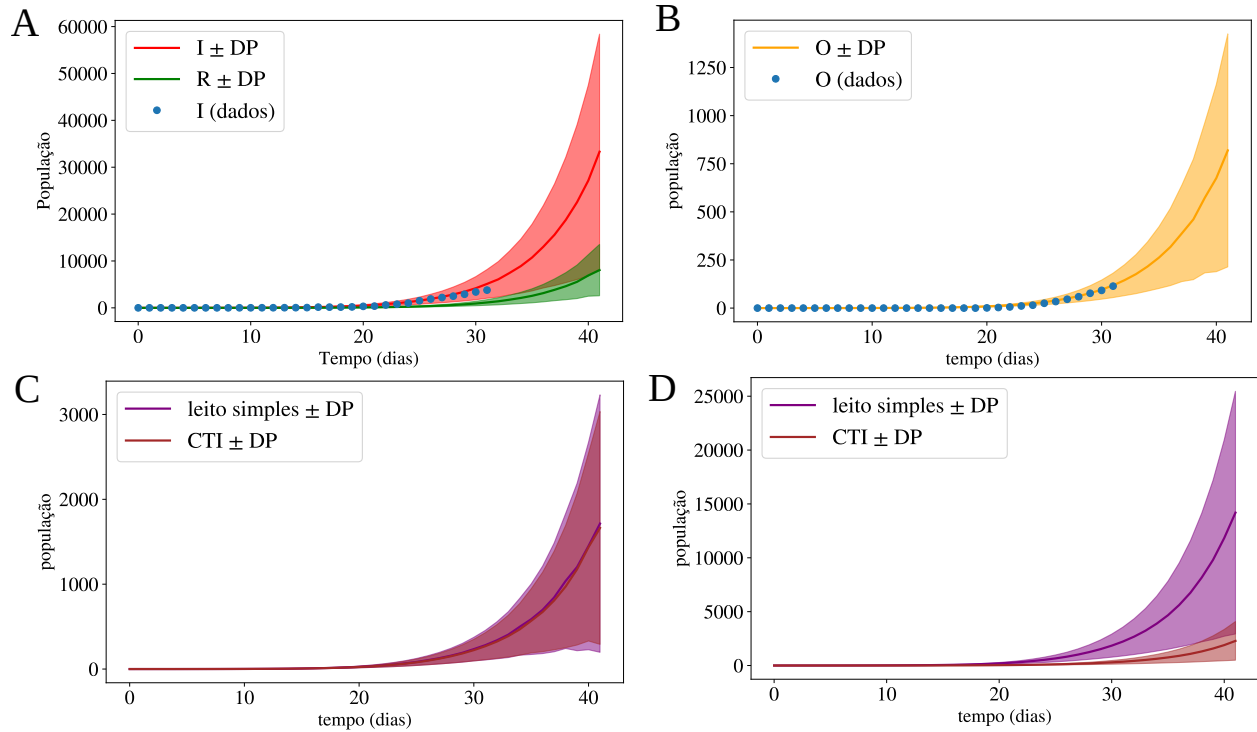


Figura 8: Resultado das simulações para o cenário do Brasil, onde o modelo é ajustado usando os dados dos primeiros 30 dias e então uma previsão é realizada para os próximos 10 dias. O dia final corresponde ao dia 7 de abril. São apresentados o número de infectados notificados (I), recuperados (R) e óbitos (O) ao longo dos dias. Previsões para o número de leitos simples e de CTI necessários com o passar dos dias são apresentados usando parâmetros estimados para o Brasil (painel C) e parâmetros que reproduzem o cenário da Itália (painel D). As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados disponíveis até o momento.

A Figura 9 apresenta a previsão para o caso do estado de Minas Gerais (MG). Para reproduzir os dados de MG, considerou-se que os parâmetros associados às características da pandemia são os mesmos obtidos pelo ajuste aos dados do Brasil. Somente foram ajustados os parâmetros associados às políticas de isolamento, obtendo-se  $t_i = 0$ ,  $t_f = 9$ ,  $r = 61\%$  e  $e = 1.6 \times 10^{-6}$ . Os parâmetros ficaram semelhantes aos do Brasil (veja Tabela 3.1), com exceção de  $t_f$ , que ficou menor, sugerindo que o estado de Minas Gerais pode ter agido mais rapidamente em relação à implementação de uma política de isolamento do que a resposta média nacional. Porém, o valor alto para  $r$ , 61%, sugere que as políticas ainda não conferiram uma redução significativa no percentual de contato.

Na Figura 9, observa-se uma estimativa de aumento para cerca de 1.300 notificações de infectados. Há também um aumento no número de óbitos ao longo do tempo, para uma estimativa de cerca de 30 pessoas no estado de MG. Os intervalos de confiança das previsões são também ilustrados na figura. O painel C da Figura 9 mostra o cenário usando os parâmetros obtidos com os escassos dados do Brasil ( $h = 7\%$ ,  $c = 8\%$ ). Neste cenário, os números de leitos, tanto simples como de UTI, aumentam para cerca de 80 cada (observado o intervalo de confiança da previsão). O painel D da Figura 9 mostra o cenário usando os parâmetros obtidos com os dados da Itália ( $h = 53\%$ ,  $c = 8.5\%$ ). Neste cenário, os números de leitos simples aumenta até 600 e o número de leitos UTI até 90 (os intervalos de confiança das previsões também são apresentados na figura).



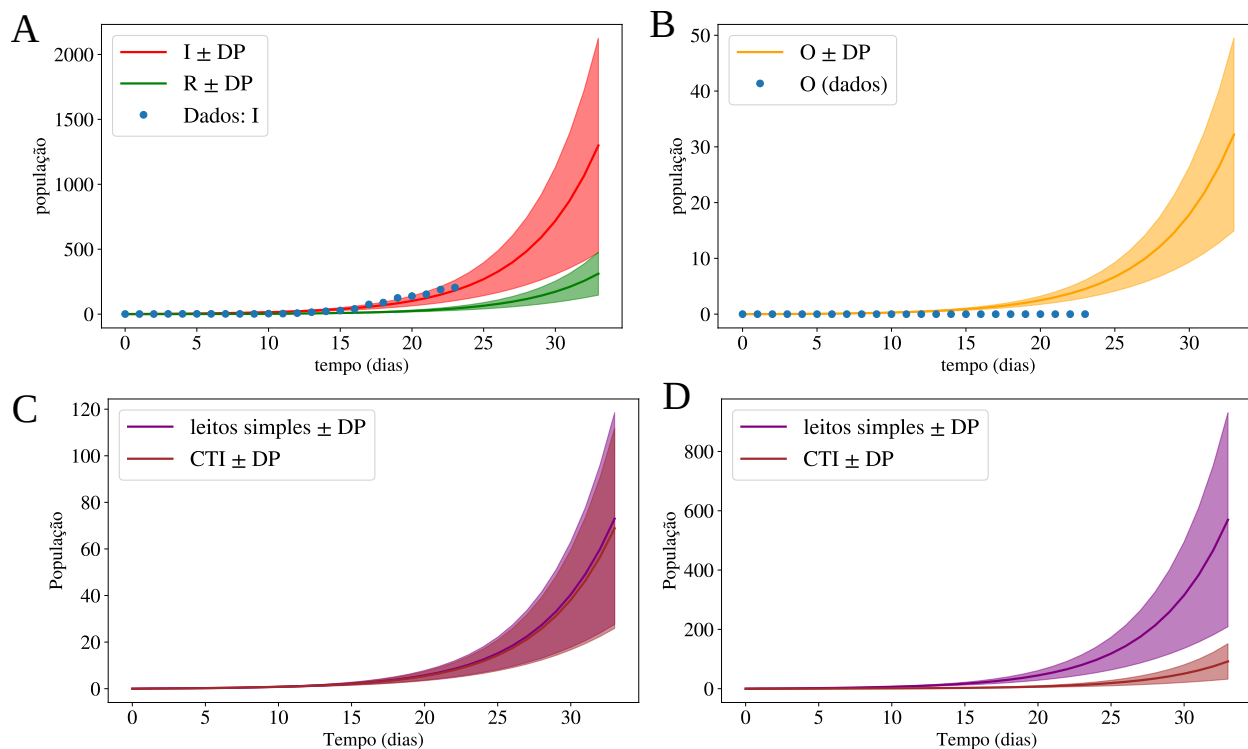


Figura 9: Resultado das simulações para o cenário do estado de Minas Gerais, onde o modelo é ajustado usando os dados dos primeiros 30 dias e então uma previsão é realizada para os próximos 10 dias. O dia final corresponde ao dia 7 de abril. São apresentados o número de infectados notificados (I), recuperados (R) e óbitos (O) ao longo dos dias. Previsões para o número de leitos simples e de CTI necessários com o passar dos dias são apresentados usando parâmetros estimados para o Brasil (painel C) e parâmetros que reproduzem o cenário da Itália (painel D). As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados disponíveis até o momento.

A Figura 10 apresenta a previsão para a cidade de Juiz de Fora. Para reproduzir os dados de Juiz de Fora, considera-se que os parâmetros associados às características da pandemia são os mesmos obtidos pelo ajuste aos dados do Brasil. Somente foram ajustados os parâmetros associados às políticas de isolamento, obtendo-se  $t_i = 0$ ,  $t_f = 8$ ,  $r = 56\%$  e  $e = 0.0$ . Observa-se que os parâmetros ficaram semelhantes ao do Brasil (veja Tabela A.3), com exceção de  $t_f$  e  $e$ , que ficaram menores, sugerindo que a cidade de Juiz de Fora pode ter agido mais rapidamente com relação a implementação de uma política de isolamento do que a resposta média nacional. Além disso, o parâmetro  $e = 0$  sugere que a cidade sofre pouca influência em relação à viagens internacionais, comparada ao estado e ao país. Porém, o valor alto para  $r$ , 56%, sugere que as políticas ainda não conferiram uma redução significativa no percentual de contato na cidade.

A Figura 10 apresenta uma estimativa de cerca de 110 notificações de novos infectados. Há também um aumento no número de óbitos ao longo do tempo, para uma estimativa de cerca de 3 pessoas na cidade de Juiz de Fora. Os intervalos de confiança das previsões são apresentados na figura. O painel C da Figura 10 mostra o cenário usando os parâmetros obtidos com os dados do Brasil ( $h = 7\%$ ,  $c = 8\%$ ). Neste cenário, os números de leitos, tanto simples como de UTI, aumentam para cerca de 7 cada (observado o intervalo de confiança da previsão). O painel D da Figura 10 mostra o cenário usando os parâmetros obtidos com os dados da Itália ( $h = 53\%$ ,  $c = 8.5\%$ ). Neste cenário, os números de leitos simples aumenta para 50 e o número de leitos UTI para 8 (os intervalos de confiança das previsões são apresentados na figura).

### 3.2.1 Cenários simulando a flexibilização das políticas de isolamento

Para estimar o impacto da flexibilização das políticas de isolamento, o valor da função  $a(t)$ , que modela a redução de contato via políticas de isolamento para contenção de transmissão, foi aumentada ao longo dos últimos 10 dias de previsão até atingir o valor de  $1.5r$ , como apresentado na Figura 4. As Figuras 13, 14 e 15 (do Apêndice) apresentam como os números de infectados notificados, óbitos, e leitos variam ao longo do tempo para este novo cenário de previsão

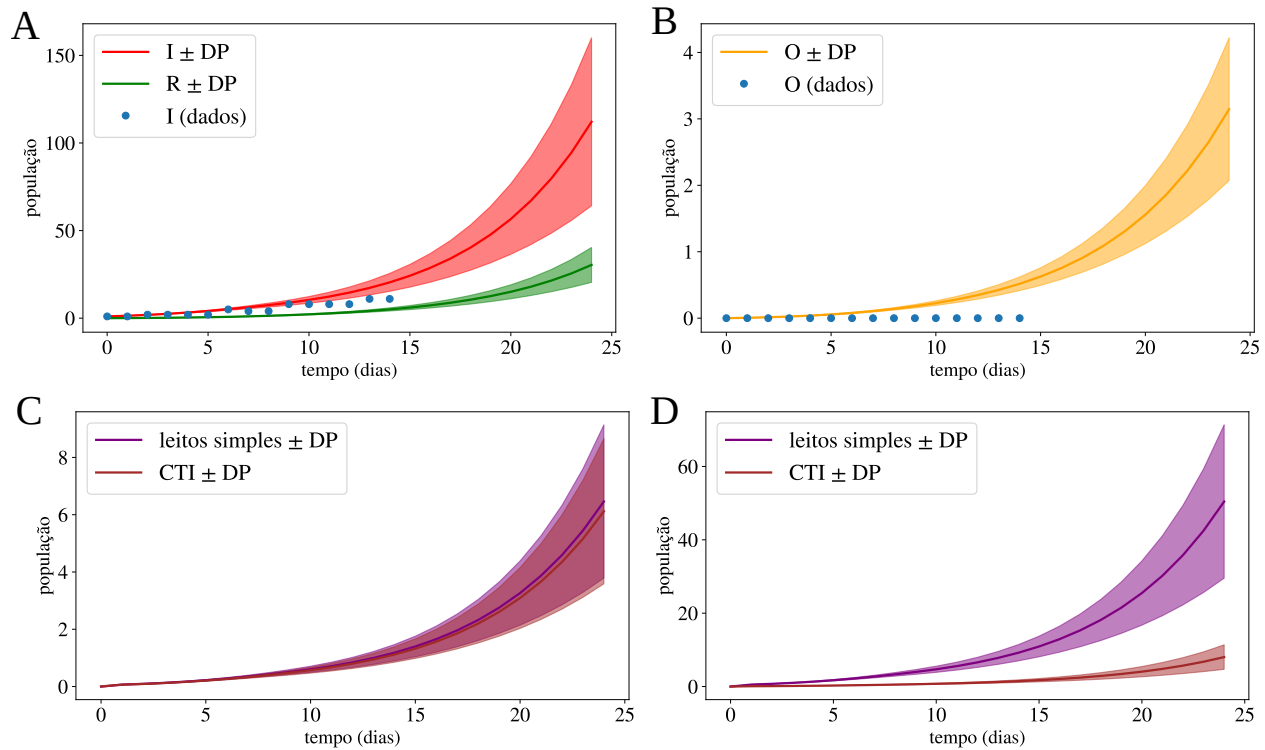


Figura 10: Resultado das simulações para o cenário da cidade de Juiz de Fora, onde o modelo é ajustado usando os dados dos primeiros 30 dias e então uma previsão é realizada para os próximos 10 dias. O dia final corresponde ao dia 7 de abril. São apresentados o número de infectados notificados (I), recuperados (R) e óbitos (O) ao longo dos dias. Previsões para o número de leitos simples e de CTI necessários com o passar dos dias são apresentados usando parâmetros estimados para o Brasil (painel C) e parâmetros que reproduzem o cenário da Itália (painel D). As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados disponíveis até o momento.

Tabela 2: Comparação entre os ajustes feitos e um cenário hipotético de flexibilização da política de isolamento de forma gradual ao longo dos próximos 10 dias (cenário aqui denominado Flex Isol.). Os valores para Média (M) - Desvio Padrão (DP) podem ser considerados como otimistas e os valores para Média (M) + Desvio Padrão (DP) como pessimistas.

	Brasil			Minas Gerais			Juiz de Fora		
	M - DP	M	M + DP	M - DP	M	M + DP	M - DP	M	M + DP
I	8.317	33.005	57.694	454	1.298	2.143	64	112	160
I Flex Isol.	17.974	52.691	87.408	735	2.425	4.115	95	192	289
O	284	838	1.392	15	32	50	2	3	4
O Flex Isol.	424	1.005	1.586	18	43	68	2	4	6
IH	3.891	14.483	25.074	344	566	909	30	50	71
IH Flex Isol.	7.389	21.231	35.073	310	951	1.593	42	78	113
IC	624	2.322	4.020	35	91	147	5	8	11
IC Flex Isol.	1.222	3.348	5.474	54	149	244	7	12	18

para o Brasil, MG e JF, respectivamente. A flexibilização do isolamento gerou aumentos significativos das previsões dessas variáveis para o dia 7 de abril.

A Tabela 2 compara as previsões para o dia 7 de abril para as variáveis do modelo usando dois cenários, o cenário de ajuste anteriormente descrito e um cenário hipotético de flexibilização da política de isolamento de forma gradual ao longo dos próximos 10 dias. Os valores para (Média - DP) podem ser interpretados como otimistas e os valores para (Média + DP) como pessimistas. Para o Brasil, a flexibilização dobrou os valores otimistas de todas as variáveis. Por exemplo, os infectados notificados aumentaram de 8.317 para 17.974 ao flexibilizar a política de isolamento. Aumentos semelhantes foram observados em todas as demais variáveis.

Situação análoga foi observada em MG. Por exemplo, os infectados notificados aumentaram, na média, de 1.298 para 2.425 com a flexibilização. Em JF, os números das variáveis aumentaram entre 50% e 100% ao considerar a flexibilização da política de isolamento. Mais detalhes sobre a comparação entre os diferentes cenários são apresentados nas Figuras 18, 17 e 16, as quais apresentam as funções de probabilidades das estimativas para o dia 7 de abril das diferentes variáveis do modelo para Juiz de Fora, Minas Gerais e Brasil, respectivamente.

## 4 Conclusões

Apresentamos um novo modelo matemático, baseado em um sistema de Equações Diferenciais Ordinárias, para representar a dinâmica da COVID-19 no Brasil, MG e Juiz de Fora. O modelo representa o número de pessoas suscetíveis, infectadas, e recuperadas; o número de óbitos; além do número de leitos hospitalares simples e de leitos UTIs necessários durante a pandemia. As condições iniciais do modelo foram ajustadas considerando a subnotificação observada. Os parâmetros do modelo foram ajustados através de métodos de otimização. A expansão polinomial Chaos, associada com o método da colocação estocástica, foi empregada para quantificar a incerteza dos resultados.

Os autores acreditam que os resultados das simulações computacionais possam auxiliar na resposta de importantes questões sobre a pandemia do COVID-19:

### 1. Quais são as características particulares da pandemia no Brasil, Minas Gerais e Juiz de Fora?

Os modelos ajustados foram comparados para três diferentes países: Coreia do Sul, Itália e Brasil. Observou-se que o percentual de óbito entre os pacientes infectados (que é distinto do cálculo feito usando a notificação de infectados) do Brasil está em torno de 1.5% e está mais próximo do valor da Coreia do Sul do que o da Itália, de 3.3%. Na Itália, 53% dos infectados notificados são hospitalizados em leitos simples, e 8.5% ocupam leitos em UTIs. Os números no Brasil são bem diferentes, sendo cerca de 7% de demanda por hospitalização em leitos simples, e 6% em UTIs. Esta diferença pode ser justificada por diferenças nas pirâmides demográficas, ou mesmo pelo Brasil ainda estar no início da pandemia. Finalmente, observou-se que a notificação de casos infectados na Coreia do Sul é alta, em torno de 85%, enquanto no Brasil e na Itália as notificações tem percentual bem baixo, em torno de 8%. Assim, estima-se que o número de infectados nesses últimos dois países é superior a  $12\times$  o número de casos notificados. Esta subnotificação dificulta o manejo da pandemia pois acrescenta maiores incertezas quanto a sua dinâmica.

### 2. Qual o impacto das políticas de contenção de transmissão?

Comparando os três países, observou-se que a Coreia do Sul adotou uma estratégia de isolamento bastante eficaz, reduzindo a transmissão do vírus para 5% de seu valor inicial. Já Brasil e Itália reduziram a taxa de transmissão apenas para metade de seu valor inicial. O mesmo foi observado em MG e JF. Considerando que o número de infectados da Coreia do Sul tem diminuído nos últimos dias, este estudo indica que as políticas de contenção de transmissão podem ser decisivas no combate contra a pandemia. Finalmente, um cenário hipotético de flexibilização da política de isolamento, realizada de forma gradual ao longo dos próximos 10 dias, foi avaliado. Para o Brasil, a flexibilização dobrou os valores otimistas de todas as variáveis. Por exemplo, os infectados notificados aumentaram de 8.317 para 17.974 ao flexibilizar a política de isolamento. Aumentos semelhantes foram observados em todas as variáveis, no Brasil, MG e JF.

Como todo modelo, este também possui limitações. Devem-se destacar os dados escassos, principalmente os referentes a internações hospitalares no Brasil. A escassez de dados aumenta as incertezas dos resultados obtidos. Outra limitação é que a população foi tratada de modo homogeneizado, não sendo considerada a pirâmide populacional, cujo emprego poderia refinar os resultados, em especial os relativos ao uso de leitos e de óbitos. Também por conta da homogeneização não foram diferenciados no modelo os chamados “superespalhadores”, pessoas que possuem uma maior rede de contato social e que, portanto, podem ser consideradas maiores disseminadores do vírus que causa a doença. Por fim, modelos determinísticos, como é o caso do modelo SIR proposto neste trabalho, podem superestimar os números de infectados,

recuperados e óbitos, durante os períodos de confinamento social. Isto porque durante o confinamento social o contato entre pessoas é reduzido. Dependendo do grau de redução do contato, um modelo estocástico poderia ser mais adequado na modelagem. A quantificação de incerteza adotada neste trabalho tenta reduzir este efeito.

### **Agradecimentos**

Os autores agradecem aos pesquisadores Guilherme Côrtes Fernandes, Thaiz Ruberti Schmal e Luis Paulo da Silva Barra pelas discussões motivadoras.

## A Apêndice

### A.1 Modelo matemático

Com o intuito de responder às questões levantadas optou-se por um modelo matemático-computacional baseado em equações diferenciais ordinárias (EDOs) do tipo SIR [11, 16, 22, 23] onde foram incluídas algumas modificações específicas.

As equações do modelo utilizado para este estudo são dadas por:

$$\frac{dS}{dt} = -\frac{\alpha}{N}SI, \quad (1)$$

$$\frac{dI}{dt} = \frac{\alpha}{N}SI + f(t) - \beta I - \gamma I, \quad (2)$$

$$\frac{dR}{dt} = \gamma I, \quad (3)$$

$$\frac{dO}{dt} = \beta I, \quad (4)$$

$$I_n = \theta I, \quad (5)$$

onde  $S$ ,  $I$ ,  $R$ ,  $O$  e  $I_n$  são as variáveis que representam o número de indivíduos de uma população com um total de  $N$  indivíduos que estão suscetíveis, infectados, recuperados, que foram a óbitos, e o número de indivíduos notificados como infectados, respectivamente.

Os parâmetros do modelo são detalhados a seguir:

- $\frac{\alpha}{N} = a(t)b/N$  representa a taxa com a qual um indivíduo suscetível se torna infectado; sendo que  $a(t)$  representa a probabilidade de contato e  $b$  é a taxa de infecção. Como a probabilidade de contato  $a(t)$  pode variar dependendo da adoção de políticas de contenção do espalhamento do vírus, este é representado como uma função do tempo, dada por:

$$a(t) = \begin{cases} 1 & t < t_i \\ \frac{1-r}{t_i-t_f}(t-t_i) + 1 & t_i \leq t \leq t_f \\ r & \text{c. c.} \end{cases} \quad (6)$$

Essa é uma abordagem simples que assume que as políticas de contenção começam a ser adotadas em  $t_i$ , e no tempo final ( $t_f$ ) a mesma consegue reduzir a probabilidade de contato em  $r\%$ .

- $\beta = m(1/\tau_o)$  representa a taxa de mortalidade dos indivíduos infectados, onde  $m$  é a taxa de mortalidade e  $\tau_o$  o número de dias da infecção até o óbito.
- $\tau_o = \tau_1 + \tau_2$ , onde  $\tau_1$  é o tempo de incubação do vírus e  $\tau_2$  é o tempo entre o aparecimento dos primeiros sintomas e o óbito. De forma similar,  $\tau_r = \tau_1 + \tau_3$ , onde  $\tau_3$  é o tempo entre o aparecimento dos primeiros sintomas e a recuperação.
- $\gamma$  representa a taxa com que indivíduos infectados se recuperam,  $\gamma = (1-m)(1/\tau_r)$ , onde  $\tau_r$  é o número de dias da infecção até a recuperação.
- $f(t) = eP(t)$  é um termo que representa o número de pessoas infectadas que entram na cidade. A hipótese considerada é que pode-se representar esse termo pelo produto de uma função  $P(t)$  do número de pessoas infectadas no mundo por uma taxa  $e$  de movimentação. Essa taxa pode ser modificada para representar as políticas de restrição.
- $\theta$  representa o percentual de pessoas infectadas e notificadas.

Para estimar o número necessário de leitos para casos com necessidade de hospitalização e de atendimento intensivo, assume-se que esse valor pode ser derivado a partir da população infectada notificada ( $I_n$ ) e do percentual dessa população que apresenta complicações severas ( $c$ ) ou graves ( $h$ ). Assim, o número de leitos em hospitais é dado pelo número de infectados hospitalizados,  $IH$ , e o número de leitos em CTIs,  $IC$ , onde:

$$IH(t) = hI_n(t - \theta\tau_1), \quad (7)$$

$$IC(t) = cI_n(t - \theta\tau_1). \quad (8)$$

Também foi assumido que o tempo notificado entre o contágio e o aparecimento dos primeiros sintomas na população notificada também é proporcional ao percentual de notificação, ou seja, igual a  $\theta\tau_1$ .

## A.2 Parâmetros

Para a calibração dos parâmetros do modelo foram utilizados dados reportados na literatura a respeito da COVID-19, como apresentados na Tabela A.2.

Tabela 3: Dados utilizados para a calibração dos parâmetros do modelo de COVID-19.

Nome	Intervalo	Unidade	Significado	Fonte
$b$	$5.5 \times 10^{-9} - 1.0 \times 10^7$	1/dia	taxa de infecção do COVID-19	[9]
$\theta$	0-1		percentual de casos infectados notificados	
$r$	0-1		fator redução da taxa de contato	
$t_i$	0-7	dia	instante inicial das pol. de contenção	
$t_f$	8-30	dia	instante final das pol. de contenção	
$c$	1-10%	-	porcentagem de casos graves	[28]
$h$	1-20%	-	porcentagem de hospitalizados	[28]
$m$	1-3.4%	-	taxa de mortalidade	[27]
$\tau_1$	2-14	dia	tempo de incubação	[23]
$\tau_2$	6-22	dia	tempo dos sintomas ao óbito	[28]
$\tau_3$	7-17	dia	tempo dos sintomas à recuperação	[28]
$e$	$0-1.0 \times 10^{-3}$		taxa de migração afetada pelas políticas de restrição	

Tabela 4: Número de habitantes utilizado como população inicial ( $N$ ).

Local	Valor
Brasil	$2.093 \times 10^8$
Coreia do Sul	$5.147 \times 10^7$
Itália	$6.048 \times 10^7$
Juiz de Fora	$5.68 \times 10^5$
Minas Gerais	$2.087 \times 10^7$

Para estimar a condição inicial das variáveis S, I, R e O foram utilizados os dados do primeiro dia de cada cenário, mas vale destacar que os dados apresentam os valores notificados, portanto foram utilizadas as seguintes relações para estimar S e I:

$$I_0 = \frac{I_{n0}}{\theta}, \quad (9)$$

$$S_0 = P_s - I_0, \quad (10)$$

onde  $P_s$  é a população de suscetíveis de cada local, *i.e.* a população  $N$  da região ou país modelado.

A.3 Resultados suplementares

Tabela 5: Caracterização da pandemia Covid-19 em diferentes países

Parâmetro	Significado	Coreia do Sul	Itália	Brasil
$b/N(\times 10^{-9})$	taxa de transmissão do COVID-19	10.88	4.62	1.82
$b(\times 10^{-1})$	taxa de transmissão do COVID-19	5.6	2.69	3.81
$r(\%)$	redução da taxa de contato	5.7	53.5	58.6
$rb(\times 10^{-9})$	taxa de contágio efetiva	3.19	14.4	22.3
$\theta(\%)$	percentual de casos infectados notificados	84.6	8.26	8.12
$t_i$	instante inicial das pol. de contenção	0	7	7
$t_f$	instante final das pol. de contenção	23	28	29
$c(\%)$	porcentagem de casos graves (UTI)	-	8.50	6.47
$h(\%)$	porcentagem de hospitalizados	-	53.4	6.83
$m(\%)$	taxa de fatalidade	1.41	3.34	1.38
$\tau_1$	tempo de incubação	12.9	13.9	13.8
$\tau_2$	tempo dos sintomas ao óbito	9.8	7.5	21.2
$\tau_3$	tempo dos sintomas à recuperação	9.9	16.9	7.1
$e(\times 10^{-6})$	pol. de restrição quanto a migração	3.1	102.1	0.46

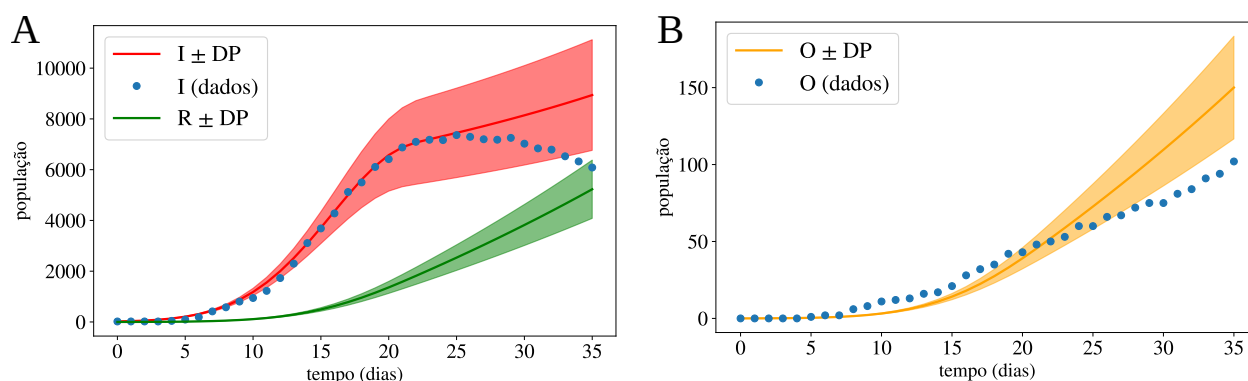


Figura 11: Resultado das simulações para o cenário da Coreia do Sul, quando apenas os dados dos primeiros 20 dias são usados para ajustar o modelo e então uma previsão é realizada para os próximos 10 dias.

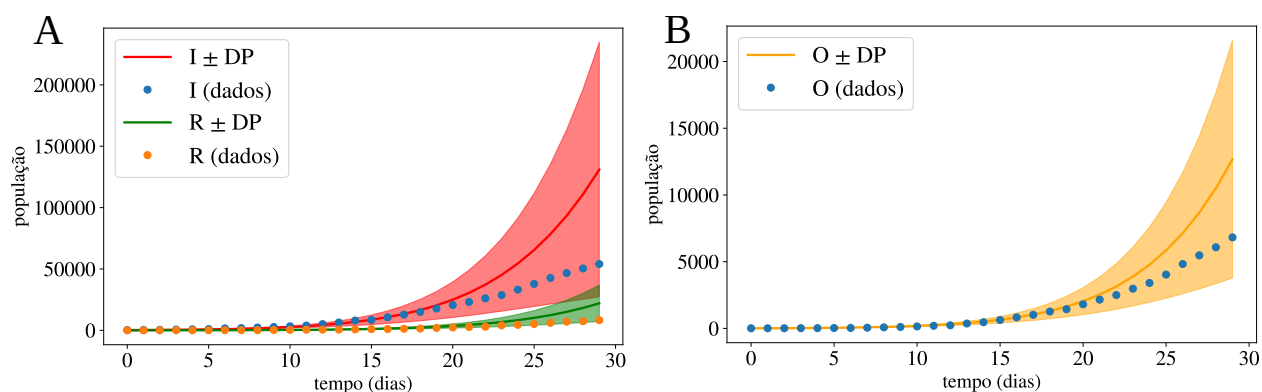


Figura 12: Resultado das simulações para o cenário da Itália, quando apenas os dados dos primeiros 20 dias são usados para ajustar o modelo e então uma previsão é realizada para os próximos 10 dias.

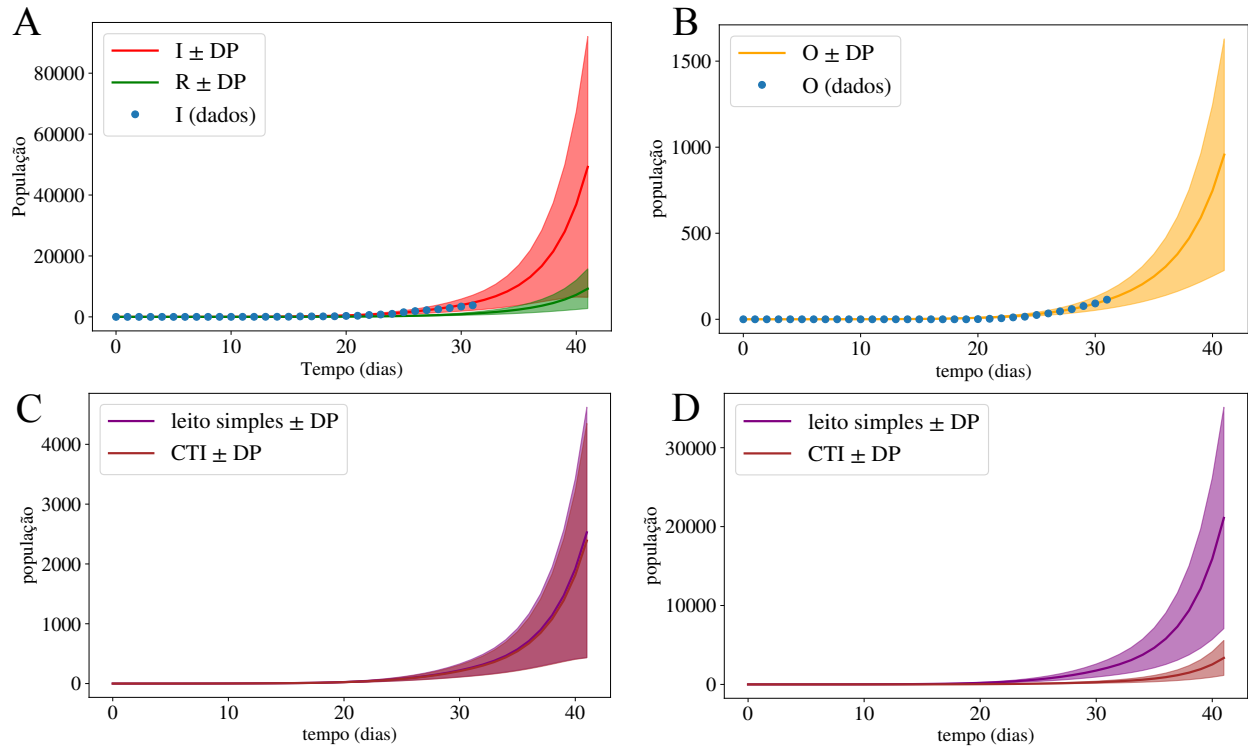


Figura 13: Resultado das simulações para o cenário do Brasil flexibilizando o isolamento, onde o modelo é ajustado usando os dados dos primeiros 30 dias e então uma previsão é realizada para os próximos 10 dias. São apresentados o número de infectados notificados (I), recuperados (R) e óbitos (O) ao longo dos dias. Previsões para o número de leitos simples e de CTI necessários com o passar dos dias são apresentados usando parâmetros estimados para o Brasil (painel C) e Itália (painel D). As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados disponíveis até o momento.



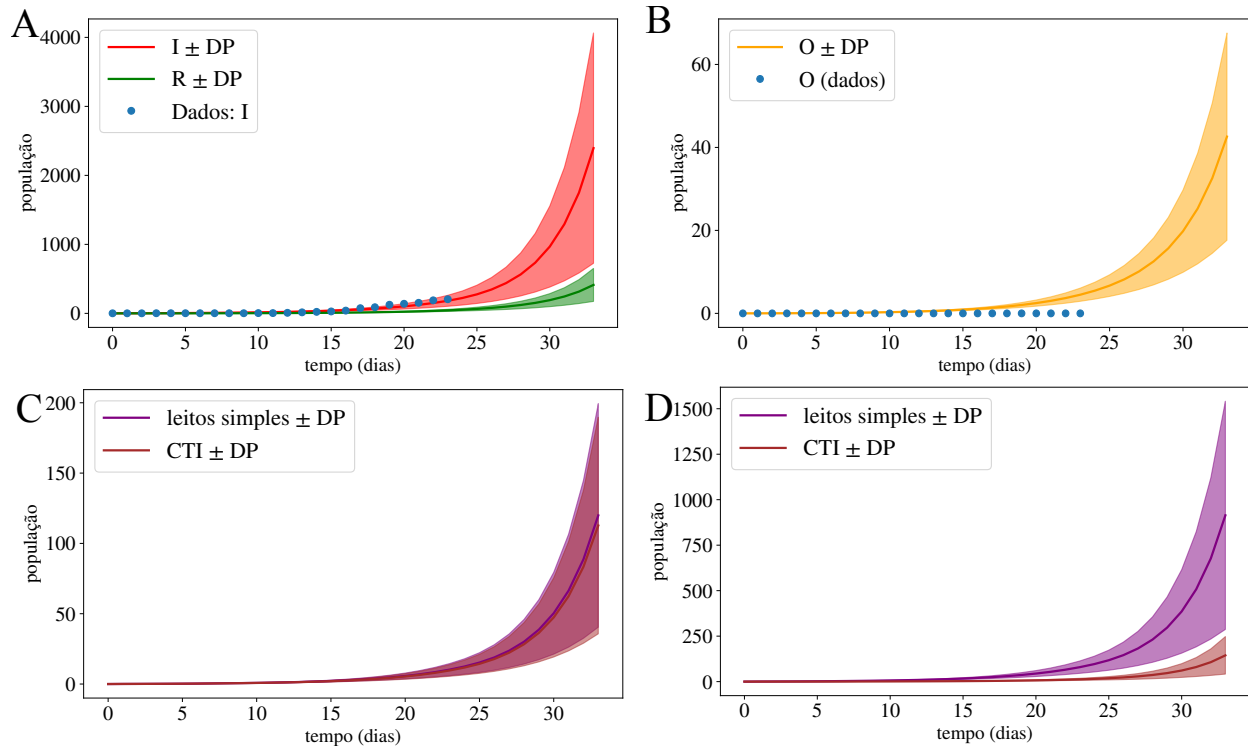


Figura 14: Resultado das simulações para o cenário de MG flexibilizando o isolamento, onde o modelo é ajustado usando os dados dos primeiros 30 dias e então uma previsão é realizada para os próximos 10 dias. São apresentados o número de infectados notificados (I), recuperados (R) e óbitos (O) ao longo dos dias. Previsões para o número de leitos simples e de CTI necessários com o passar dos dias são apresentados usando parâmetros estimados para o Brasil (painel C) e Itália (painel D). As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados disponíveis até o momento.

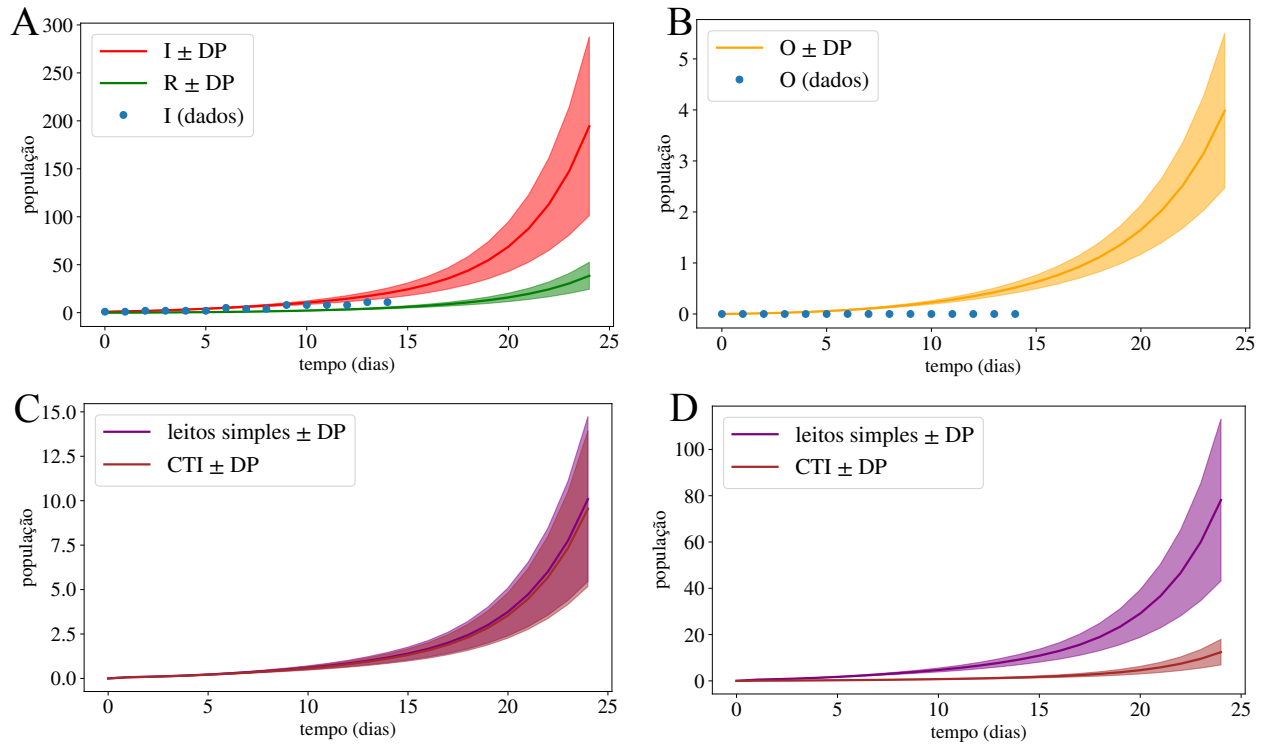


Figura 15: Resultado das simulações para o cenário de JF flexibilizando o isolamento, onde o modelo é ajustado usando os dados dos primeiros 30 dias e então uma previsão é realizada para os próximos 10 dias. O início da simulação corresponde ao dia 14/03/2020 e o fim ao dia 07/04/2020 (28/03/2020 acrescido dos 10 dias de previsão). São apresentados o número de infectados notificados (I), recuperados (R) e óbitos (O) ao longo dos dias. Previsões para o número de leitos simples e de CTI necessários com o passar dos dias são apresentados usando parâmetros estimados para o Brasil (painel C) e Itália (painel D). As linhas sólidas indicam o valor médio, regiões hachuradas o desvio padrão (DP) dos resultados das simulações, enquanto os pontos são os dados disponíveis até o momento.

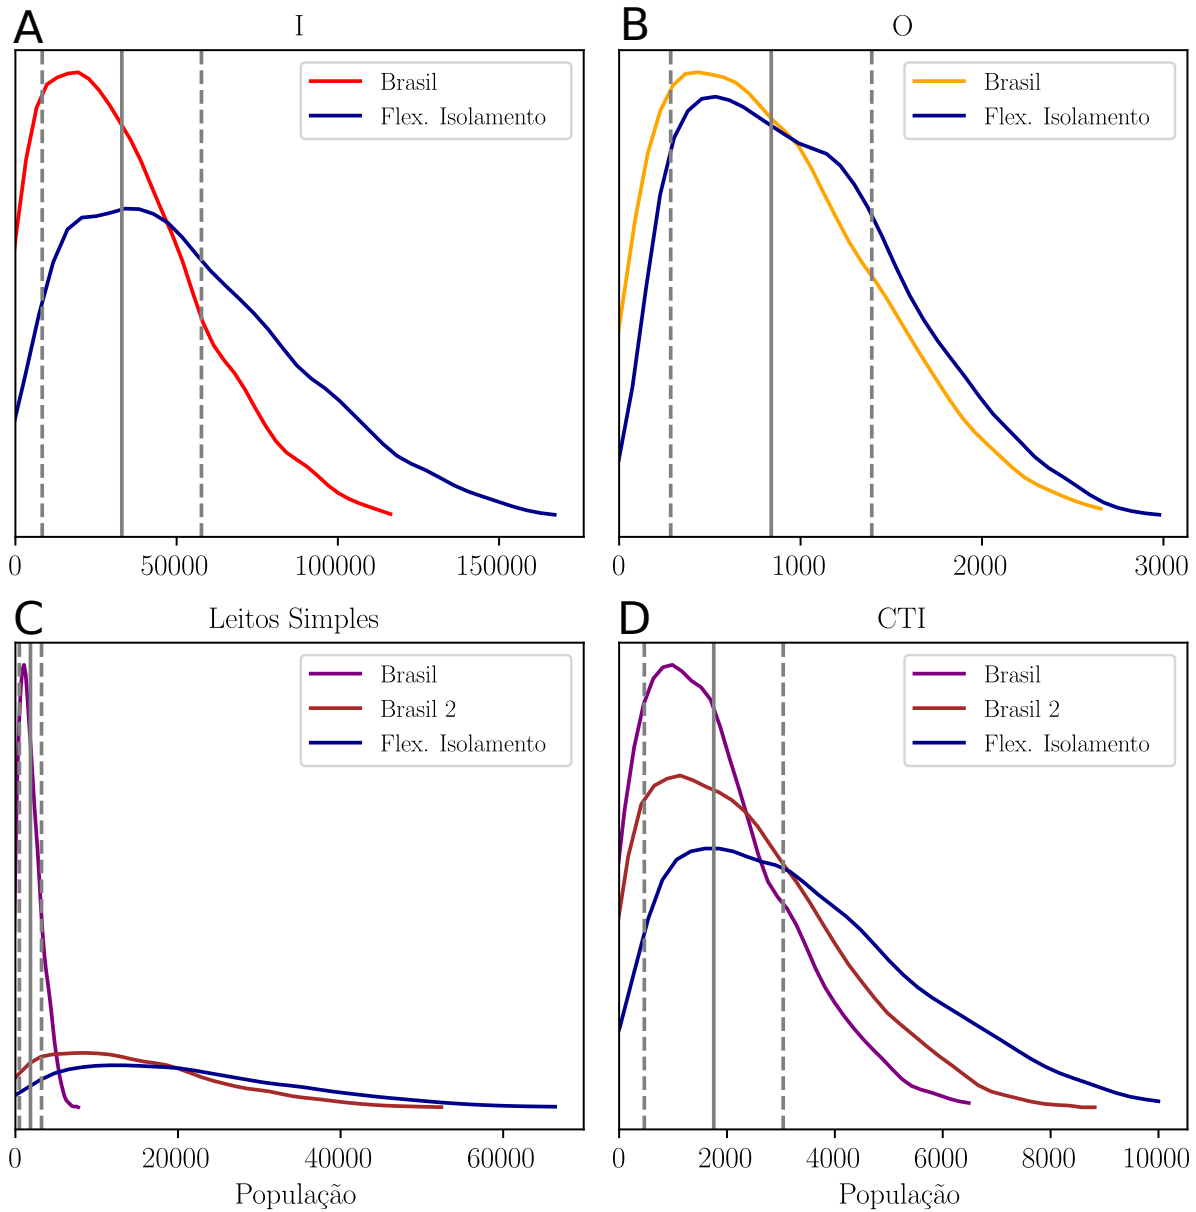


Figura 16: Função densidade de probabilidade das variáveis Infectados (I), Óbitos (O), Leitos Simples e CTI, para o cenário do Brasil no último dia de previsão do modelo. Painéis (A) e (B) comparam os ajustes feitos com um cenário hipotético de flexibilização da política de isolamento de forma gradual ao longo dos próximos 10 dias (Flex. Isolamento). Painéis (C) e (D) comparam os resultados usando parâmetros estimados para o Brasil, Itália (Brasil 2) e Flex. Isolamento. Linha sólida vertical em cinza indica o valor médio e as linhas tracejadas o desvio padrão.

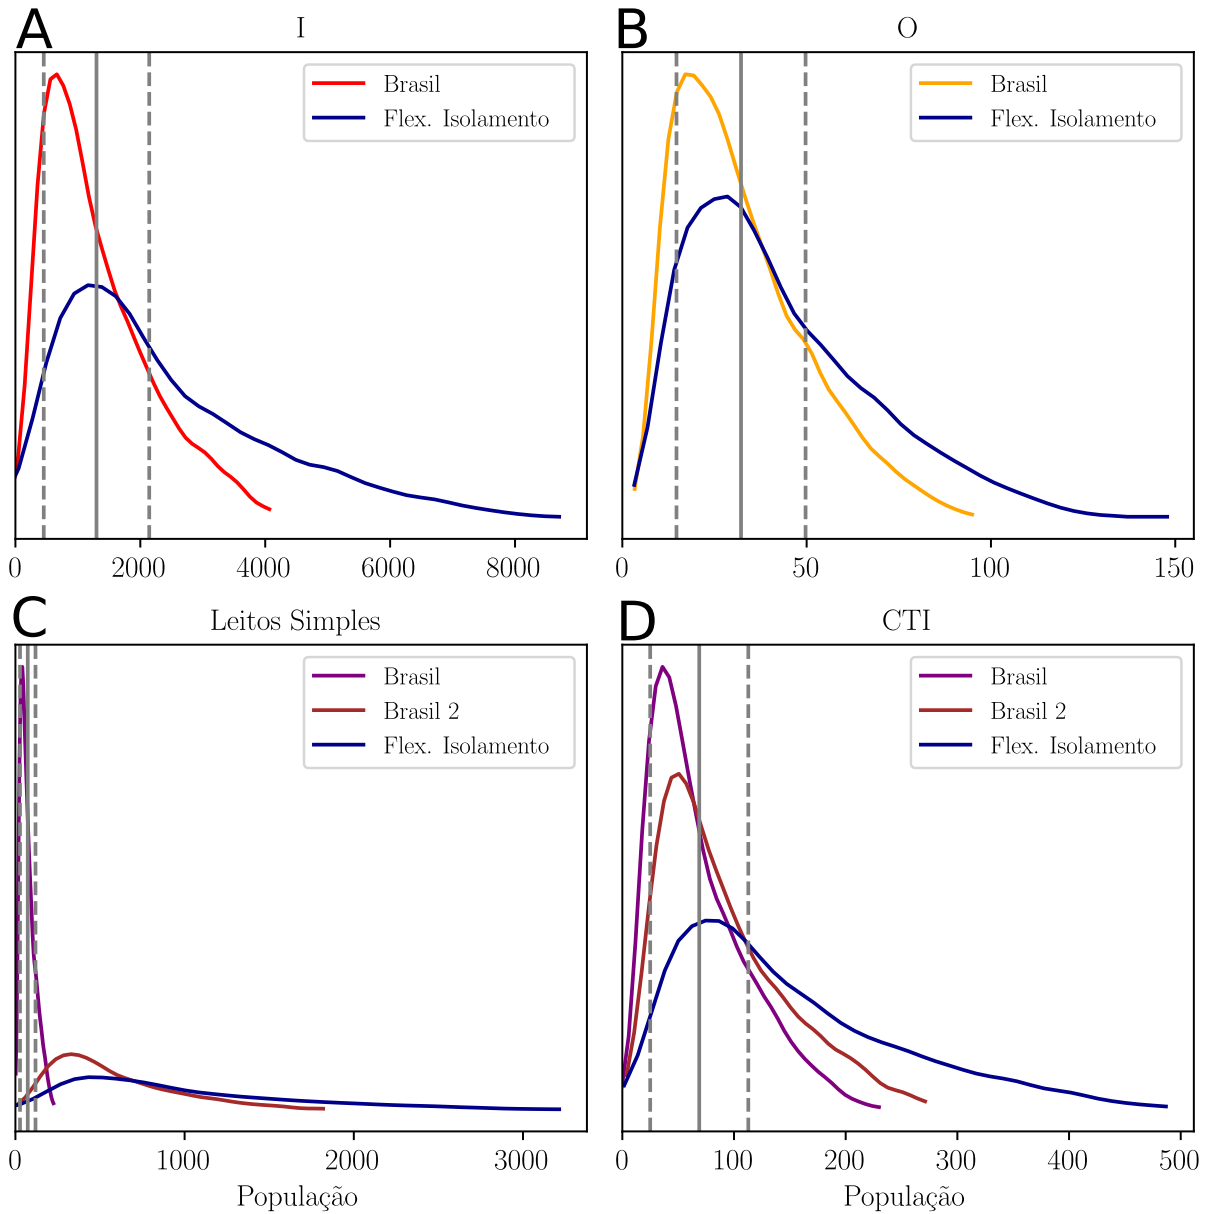


Figura 17: Função densidade de probabilidade das variáveis Infectados (I), Óbitos (O), Leitos Simples e CTI, para o cenário de Minas Gerais no último dia de previsão do modelo. Painéis (A) e (B) comparam os ajustes feitos com um cenário hipotético de flexibilização da política de isolamento de forma gradual ao longo dos próximos 10 dias (Flex. Isolamento). Painéis (C) e (D) comparam os resultados usando parâmetros estimados para o Brasil, Itália (Brasil 2) e Flex. Isolamento. Linha sólida vertical em cinza indica o valor médio e as linhas tracejadas o desvio padrão.

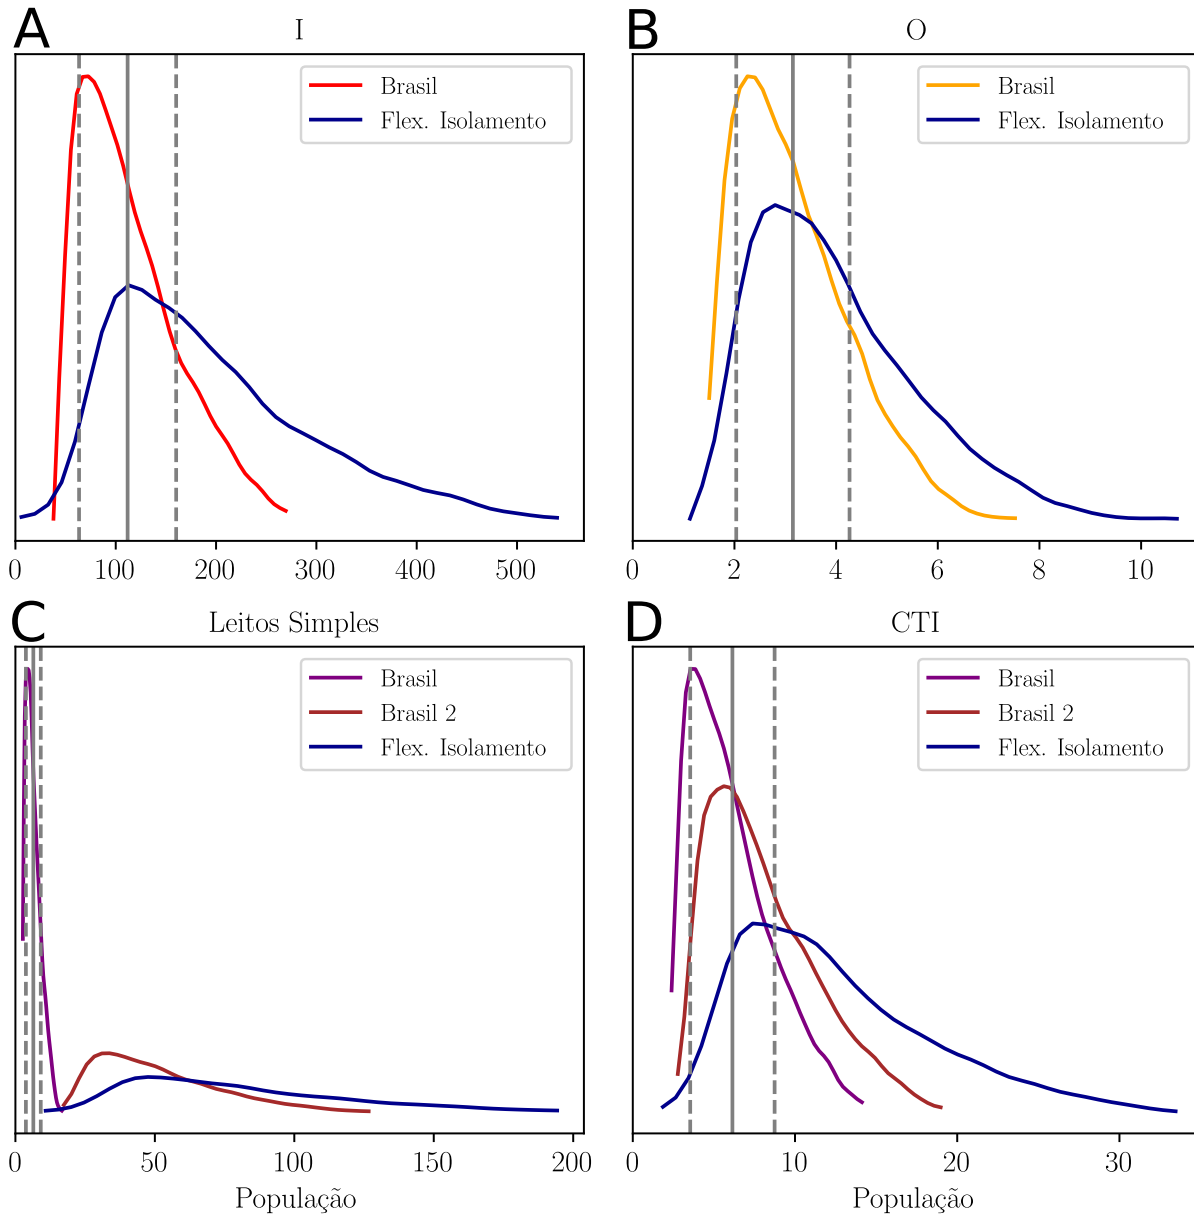


Figura 18: Função densidade de probabilidade das variáveis Infectados (I), Óbitos (O), Leitos Simples e CTI, para o cenário de Juiz de Fora no último dia de previsão do modelo. Painéis (A) e (B) comparam os ajustes feitos com um cenário hipotético de flexibilização da política de isolamento de forma gradual ao longo dos próximos 10 dias (Flex. Isolamento). Painéis (C) e (D) comparam os resultados usando parâmetros estimados para o Brasil, Itália (Brasil 2) e Flex. Isolamento. Linha sólida vertical em cinza indica o valor médio e as linhas tracejadas o desvio padrão.

## Referências

- [1] J. O. CAMPOS, J. SUNDNES, R. W. DOS SANTOS, AND B. M. ROCHA, *Effects of left ventricle wall thickness uncertainties on cardiac mechanics*, Biomechanics and modeling in mechanobiology, 18 (2019), pp. 1415–1427.
- [2] DIPARTIMENTO DELLA PROTEZIONE CIVILE, *COVID-19 Italia - Monitoraggio situazione*. <https://github.com/pcm-dpc/COVID-19>, 2020.
- [3] V. G. ECK, W. P. DONDEERS, J. STURDY, J. FEINBERG, T. DELHAAS, L. R. HELLEVIK, AND W. HUBERTS, *A guide to uncertainty quantification and sensitivity analysis for cardiovascular applications*, International journal

- for numerical methods in biomedical engineering, 32 (2016), p. e02755.
- [4] D. FANELLI AND F. PIAZZA, *Analysis and forecast of COVID-19 spreading in China, Italy and France*, Chaos, Solitons & Fractals, 134 (2020), p. 109761.
- [5] A. R. FEHR AND S. PERLMAN, *Coronaviruses: an overview of their replication and pathogenesis*, Methods in Molecular Biology (Clifton, N.J.), 1282 (2015), pp. 1–23.
- [6] J. FEINBERG AND H. P. LANGTANGEN, *Chaospy: An open source tool for designing methods of uncertainty quantification*, Journal of Computational Science, 11 (2015), pp. 46–57.
- [7] N. FERGUSON, D. LAYDON, G. NEDJATI GILANI, N. IMAI, K. AINSLIE, M. BAGUELIN, S. BHATIA, A. BOONYASIRI, Z. CUCUNUBA PEREZ, G. CUOMO-DANNENBURG, A. DIGHE, I. DORIGATTI, H. FU, K. GAYTHORPE, W. GREEN, A. HAMLET, W. HINSLEY, L. OKELL, S. VAN ELSLAND, H. THOMPSON, R. VERITY, E. VOLZ, H. WANG, Y. WANG, P. WALKER, P. WINSKILL, C. WHITTAKER, C. DONNELLY, S. RILEY, AND A. GHANI, *Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand*, report, Imperial College London, Mar. 2020. Accepted: 2020-03-17T09:57:15Z.
- [8] G. GRASSELLI, A. PESENTI, AND M. CECCONI, *Critical Care Utilization for the COVID-19 Outbreak in Lombardy, Italy: Early Experience and Forecast During an Emergency Response*, JAMA, (2020).
- [9] J. JIA, J. DING, S. LIU, G. LIAO, J. LI, B. DUAN, G. WANG, AND R. ZHANG, *Modeling the control of covid-19: Impact of policy interventions and meteorological factors*, 2020.
- [10] JOHNS HOPKINS UNIVERSITY, *2019 novel coronavirus covid-19 (2019-ncov) data repository by johns hopkins university center for systems science and engineering*. <https://github.com/CSSEGISandData/COVID-19>, 2020.
- [11] M. J. KEELING AND P. ROHANI, *Modeling infectious diseases in humans and animals*, Princeton University Press, 2011.
- [12] V. J. LEE, C. J. CHIEW, AND W. X. KHONG, *Interrupting transmission of COVID-19: lessons from containment efforts in Singapore*, Journal of Travel Medicine, (2020).
- [13] G. D. B. MINISTÉRIO DA SAÚDE, *Painel do surto de vírus covid-19 no brasil*, 2020. Acessado em 27 de Março de 2020.
- [14] G. M. NOVAES, J. O. CAMPOS, E. ALVAREZ-LACALLE, S. A. MUÑOZ, B. M. ROCHA, AND R. W. DOS SANTOS, *Combining polynomial chaos expansions and genetic algorithm for the coupling of electrophysiological models*, in Computational Science – ICCS 2019, J. M. F. Rodrigues, P. J. S. Cardoso, J. Monteiro, R. Lam, V. V. Krzhizhanovskaya, M. H. Lees, J. J. Dongarra, and P. M. Slood, eds., Cham, 2019, Springer International Publishing, pp. 116–129.
- [15] T. E. OLIPHANT, *Python for scientific computing*, Computing in Science & Engineering, 9 (2007), pp. 10–20.
- [16] B. D. M. QUINTELA, J. M. CONWAY, J. M. HYMAN, J. GUEDJ, R. W. DOS SANTOS, M. LOBOSCO, AND A. S. PERELSON, *A new age-structured multiscale model of the hepatitis c virus life-cycle during infection and therapy with direct-acting antiviral agents*, Frontiers in microbiology, 9 (2018), p. 601.
- [17] A. REMUZZI AND G. REMUZZI, *COVID-19 and Italy: what next?*, The Lancet, 0 (2020). Publisher: Elsevier.
- [18] K. ROOSA, Y. LEE, R. LUO, A. KIRPICH, R. ROTHENBERG, J. M. HYMAN, P. YAN, AND G. CHOWELL, *Real-time forecasts of the COVID-19 epidemic in China from February 5th to February 24th, 2020*, Infectious Disease Modelling, 5 (2020), pp. 256–263.
- [19] SES-MG, *Informe Epidemiológico Coronavírus 28/03/2020 | Secretaria de Estado de Saúde de Minas Gerais - SES*, 2020. Acessado em 28 de Março de 2020.
- [20] C. SOHRABI, Z. ALSAFI, N. O’NEILL, M. KHAN, A. KERWAN, A. AL-JABIR, C. IOSIFIDIS, AND R. AGHA, *World Health Organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19)*, International Journal of Surgery, 76 (2020), pp. 71–76.
- [21] R. STORN AND K. PRICE, *Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces*, Journal of global optimization, 11 (1997), pp. 341–359.
- [22] V. C. VARELLA, A. M. F. MATOS, H. C. TEIXEIRA, A. DA CONCEIÇÃO OLIVEIRA COELHO, R. W. DOS SANTOS, AND M. LOBOSCO, *A stochastic model to simulate the spread of leprosy in juiz de fora*, in ICCS, 2018.
- [23] H. WANG, Z. WANG, Y. DONG, R. CHANG, C. XU, X. YU, S. ZHANG, L. TSAMLAK, M. SHANG, J. HUANG, ET AL., *Phase-adjusted estimation of the number of coronavirus disease 2019 cases in wuhan, china*, Cell Discovery, 6 (2020), pp. 1–8.

- [24] A. WILDER-SMITH, C. J. CHIEW, AND V. J. LEE, *Can we contain the COVID-19 outbreak with the same measures as for SARS?*, *The Lancet Infectious Diseases*, (2020).
- [25] A. WILDER-SMITH AND D. O. FREEDMAN, *Isolation, quarantine, social distancing and community containment: pivotal role for old-style public health measures in the novel coronavirus (2019-nCoV) outbreak*, *Journal of Travel Medicine*, 27 (2020). taaa020.
- [26] WORLD HEALTH ORGANIZATION, *Virtual press conference on covid-19 - 11 march 2020*. [https://www.who.int/docs/default-source/coronaviruse/transcripts/who-audio-emergencies-coronavirus-press-conference-full-and-final-11mar2020.pdf?sfvrsn=cb432bb3\\_2](https://www.who.int/docs/default-source/coronaviruse/transcripts/who-audio-emergencies-coronavirus-press-conference-full-and-final-11mar2020.pdf?sfvrsn=cb432bb3_2), 2020. Acessado em 24 de Março de 2020.
- [27] ———, *Who director-general's opening remarks at the media briefing on covid-19 - 3 march 2020*. <https://www.who.int/dg/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---3-march-2020>, 2020. Acessado em 24 de Março de 2020.
- [28] WORLDOMETERS.INFO, *Covid-19 coronavirus pandemic*, 2020. Acessado em 27 de Março de 2020.
- [29] Z. WU AND J. M. MCGOOGAN, *Characteristics of and Important Lessons From the Coronavirus Disease 2019 (COVID-19) Outbreak in China: Summary of a Report of 72314 Cases From the Chinese Center for Disease Control and Prevention*, *JAMA*, (2020).

As análises e previsões aqui divulgadas representam as opiniões dos autores envolvidos no estudo e não necessariamente das instituições as quais são associados.