

Um modelo SEIRD generalizado com mecanismo implícito de quarentena para a disseminação da COVID-19: uma abordagem Bayesiana

Regina C. Almeida¹

Diego Tavares Volpatto^{1,2}, Anna Claudia Mello de Resende¹, Lucas dos Anjos¹, João Vitor Oliveira Silva¹, Claudia Mazza Dias³, Sandra Mara Cardoso Malta¹

COLMEA, UERJ

¹ Laboratório Nacional de Computação Científica

² ESSS, Engineering Simulation and Scientific Software

³ Universidade Federal Rural do Rio de Janeiro

25/06/2020



Laboratório
Nacional de
Computação
Científica

Equipe



Sandra Malta, D.Sc., LNCC



Claudia M. Dias, D.Sc., UFRRJ




Diego T. Volpatto, M.Sc., LNCC



Anna C.M. Resende, M.Sc., LNCC



Lucas dos Anjos, D.Sc., LNCC



João V.O. Silva, B.Sc., LNCC

- Introdução
- Modelagem Matemática & Métodos
 - Modelo
 - Dados
 - Calibração Bayesiana
 - Análise de Sensibilidade
- Resultados
- Observações Finais

Introdução - A COVID-19 no mundo

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

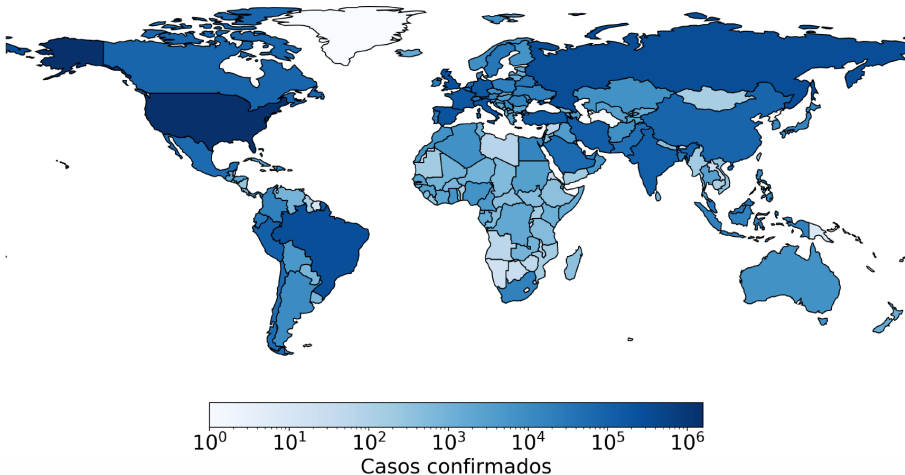


Figura 1: Distribuição mundial dos casos confirmados de COVID-19 até 21/05/2020. Dados retirados do repositório da Johns Hopkins University.

Introdução - A COVID-19 no Brasil





Figura 2: Linha do tempo da evolução de casos confirmados e total de óbitos para o Brasil até 21/05/2020. Dados do Ministério da Saúde - MS.



Números: Brasil

- “falta” de dados confiáveis
- capacidade de testagem limitada
- política de testagem restrita
- subnotificações
- heterogeneidade sócio-demográfica

Modelo Matemático (BR/RJ)

- generalização do modelo SEIRD
- quarentena (distanciamento social)
- incertezas

Introdução - Por que modelo do tipo SEIRD?

SEIRD: Susceptible-Exposed-Infected-Recovered-Dead

Características

- equações diferenciais ordinárias
- homogeneidade espacial
- $S(t) + E(t) + I(t) + R(t) + D(t) = N \rightarrow$ população total
- “simples”

O que (não) se conhece sobre a COVID-19?

- tempo de latência: 3 a 7 dias
- indivíduos infectados podem ou não apresentar sintomas: infectados sintomáticos e assintomáticos
- tempo de recuperação: cerca de 14 dias
- imunidade

Introdução - A dinâmica da COVID-19

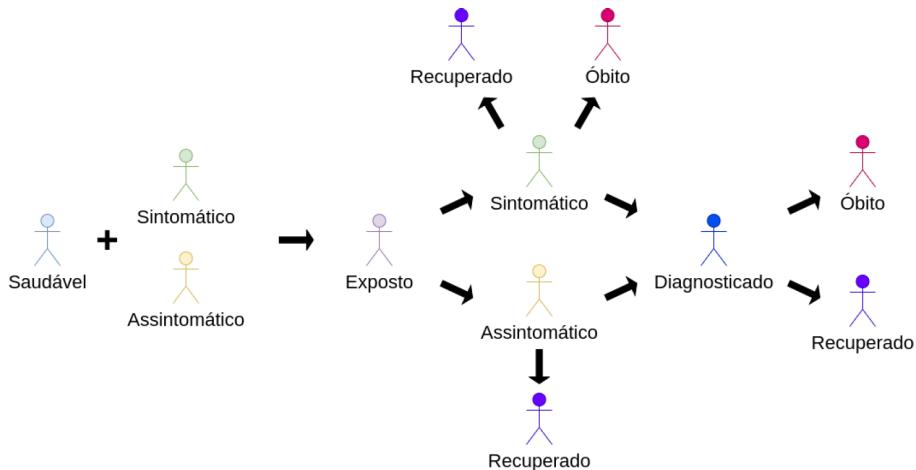


Figura 3: Evolução do estado de um indivíduo inicialmente saudável/suscetível.

Modelo Matemático: SEAIRPD-Q

► “Essentially, all models are wrong, but some are useful.” George Box

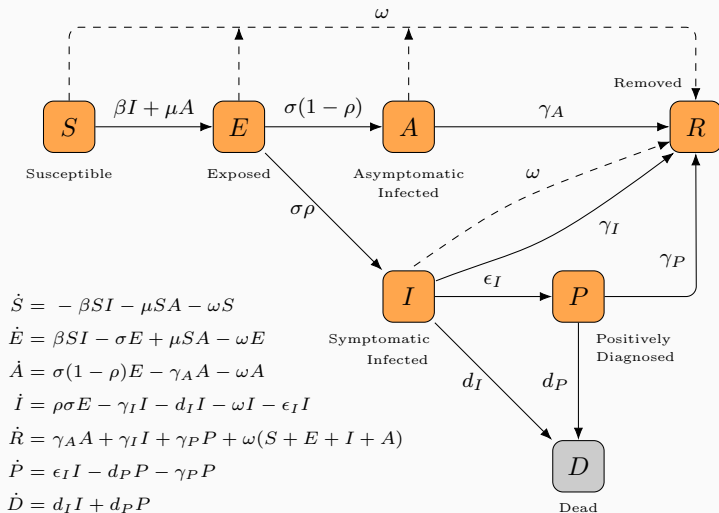


Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

- β, μ : Taxas de transmissão por contato com indivíduos infectados I e A ;

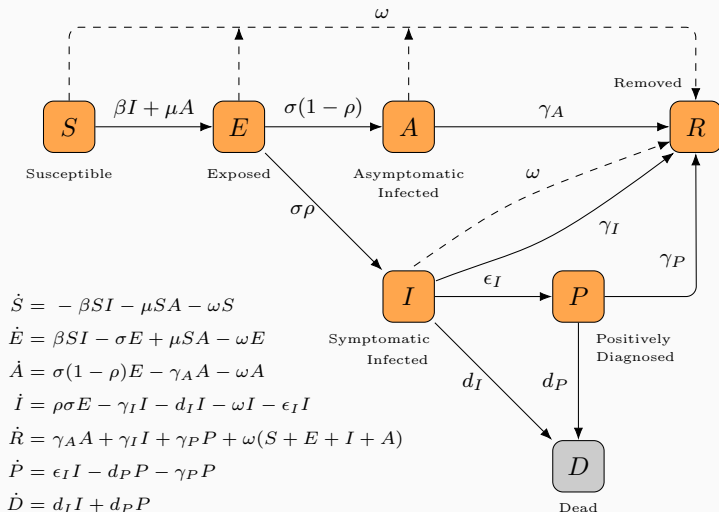


Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

► σ : Taxa de transição de E para I e A ;




Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

- ρ : Proporção de indivíduos infectados que apresentam sintomas;




Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

- ϵ_I : Taxa de diagnóstico (de indivíduos infectados qua apresentam sintomas);




Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

► $\gamma_A, \gamma_I, \gamma_P$: Taxas de recuperação de A, I e P , respectivamente;




Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

► d_I, d_P : Taxas de mortalidade de I e P ;




Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Modelo Matemático: SEAIRPD-Q

► ω : Taxa em que S , E , I , e A são removidos (colocados em isolamento) devido à medidas de quarentena.

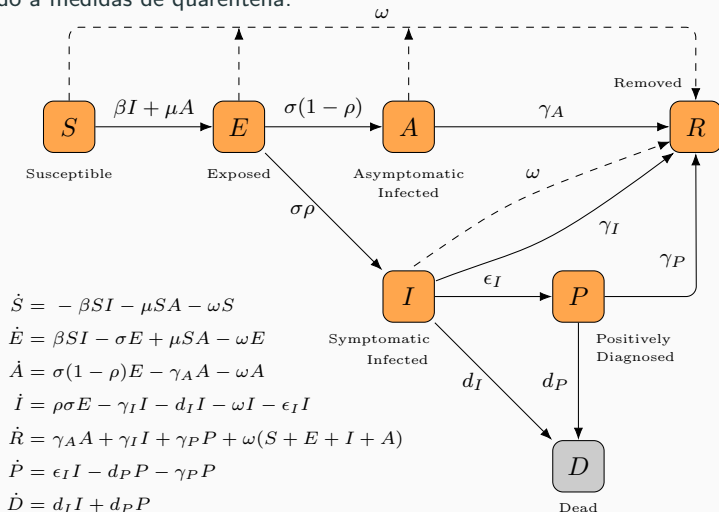


Figura 4: Descrição esquemática do modelo SEAIRPD-Q.

Número de Reprodução

Calculado usando o método *Next Generation Matrix*¹:

- vetor: $\mathbf{x}^T = [E, I, A]$
- $\frac{d\mathbf{x}}{dt} = (T + \Sigma)\mathbf{x}$, $T = \begin{bmatrix} 0 & \beta S & \mu S \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$ e $-\Sigma = \begin{bmatrix} \sigma + \omega & 0 & 0 \\ -\sigma\rho & \gamma_I + d_I + \omega + \epsilon_I & 0 \\ -\sigma(1-\rho) & 0 & \gamma_A + \omega \end{bmatrix}$
- \mathcal{R}_0 é o autovalor dominante da matriz $K = -T\Sigma^{-1}$

Número básico de reprodução

$$\mathcal{R}_0 = \left(\frac{\sigma(1-\rho)\mu}{(\sigma + \omega)(\gamma_A + \omega)} + \frac{\beta\sigma\rho}{(\sigma + \omega)(\gamma_I + d_I + \omega + \epsilon_I)} \right) S(0)$$

Número efetivo de reprodução

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

¹Diekmann et al., *Journal of The Royal Society Interface*, 7:873–885, 2010.

Casos acumulados de confirmados e óbitos

- BR: <https://covid.saude.gov.br/>
dados epidemiológicos de 63 dias: de 05/03 a 06/05
- RJ: <https://covid19br.wcota.me>
dados epidemiológicos de 53 dias: de 10/03 a 01/05

Dia 0 epidemiológico (t_0): pelo menos 5 casos confirmados

SBMAC: A Matemática Aplicada na pandemia de COVID-19

- Notebook (Python): <https://www.kaggle.com/resendeacm/covid-19-rio-de-janeiro-city>
- Dataset: <https://www.kaggle.com/resendeacm/covid-19-rio-de-janeiro-city>

Model Calibration

θ : Vetor de “parâmetros”


\mathbf{y} : Medidas experimentais

π : Função densidade de probabilidade

$$\pi_{\text{post}}(\theta|\mathbf{y}) = \frac{\pi_{\text{like}}(\mathbf{y}|\theta) \cdot \pi_{\text{prior}}(\theta)}{\pi_{\text{evid}}(\mathbf{y})}$$

- π_{prior} : conhecimento inicial sobre θ
- π_{like} : função de verossimilhança de \mathbf{y} dado θ
- π_{evid} : informação contida em \mathbf{y}
- π_{post} : conhecimento atualizado sobre θ dado \mathbf{y} .

Hierarquia de cenários



Calibração Bayesiana

- Parâmetros calibrados: $\{\beta = \mu, d_I, d_P, \omega\}$ e $\{\sigma_C, \sigma_D\}$
- Ruídos nos dados: $\mathcal{N}(0, \sigma_C^2)$ e $\mathcal{N}(0, \sigma_D^2)$
- Quantidades observadas C e D :

$$C(t_i) := y_{\text{model}}^C(t_i) = \int_{t_0}^{t_i} \varepsilon_I I(t) dt \quad \text{e} \quad D(t_i) := y_{\text{model}}^D(t_i) = \int_{t_0}^{t_i} [d_I I(t) + d_P P(t)] dt$$

Função de Verossimilhança

$$\pi_{\text{like}}(\mathbf{y}|\boldsymbol{\theta}) = \prod_{j \in \{C, D\}} \frac{1}{\sigma_j \sqrt{2\pi}} \exp \left(-\frac{1}{2} \sum_{i=1}^n \left(\frac{y^{(j)}(t_i) - y_{\text{model}}^{(j)}(t_i)}{\sigma_j} \right)^2 \right)$$

- Calibração realizada usando PyMC3
- Resolução do problema inverso utiliza o método CATMIP (*Cascading Adaptive Transitional Metropolis in Parallel*)

Por que?

- Como as incertezas nos parâmetros afetam a QoI selecionada?
- Contribui para um melhor entendimento sobre o modelo.

Número Efetivo de Reprodução

$$QoI_1(t) = \mathcal{R}(t)$$

Soma Quadrada Normalizada

$$QoI_2(t) = \sqrt{C(t)^2 + D(t)^2}$$

- **Elementary Effects Method** (Morris, 1991²)
- Hipótese: para cada parâmetro $\bar{\theta}_i$ analisado: $\theta_i \sim \mathcal{U}(0.5\bar{\theta}_i, 1.5\bar{\theta}_i)$

²Campolongo et al. An effective screening design for sensitivity analysis of large models. Environmental modelling & software, 22(10):1509–1518, 2007

Resultados - Calibração para o estado do Rio de Janeiro


Tabela 1: Condições Iniciais.

Classe	População Inicial (Ind.)	Fonte
N	17.264.943	IBGE 2019
$P(0)$	8	Dados do dia 10-03-2020
$E(0)$	$10 \cdot P(0)$	
$I(0)$	$5 \cdot P(0)$	
$A(0)$	$P(0)$	
$D(0)$	0	Dados do dia 10-03-2020
$R(0)$	0	Dados do dia 10-03-2020
$S(0)$	17.264.837	$S(0) = N - \{E(0) + A(0) + I(0) + P(0) + R(0) + D(0)\}$


Tabela 2: Valores fixados e mais prováveis (MAP) (u.a.).

Parâmetro	Valor/MAP (RJ)	π_{prior}	Source
$\beta = \mu$	4.658646×10^{-8}	$\mathcal{U}(0, 1 \times 10^{-5})$	CATMIP
σ	1/5	–	*
ρ	0.85	–	*
ε_I	1/3	–	*
$\gamma_A, \gamma_I, \gamma_P$	1/14	–	*
d_I	5.549912×10^{-4}	$\mathcal{U}(0, 0.1)$	CATMIP
d_P	1.315661×10^{-2}	$\mathcal{U}(0, 0.1)$	CATMIP
ω	1.970400×10^{-2}	$\mathcal{U}(0, 1)$	CATMIP
\mathcal{R}_0	2.830033	–	NGM
σ_C	148	$\mathcal{U}(1, 10000)$	CATMIP
σ_D	22	$\mathcal{U}(1, 10000)$	CATMIP


Distribuições a posteriori




(A) Calibrated parameter: β .



(B) Calibrated parameter: ω .



(C) Calibrated parameter: d_I .



(D) Calibrated parameter: d_P .

Projeções





Figura 5: Predições de P , I , A , D e C para o Rio de Janeiro. As linhas verticais pontilhadas indicam o intervalo de credibilidade de 95% para o pico dos infectados, cuja distribuição é apresentada à direita.

Projeções



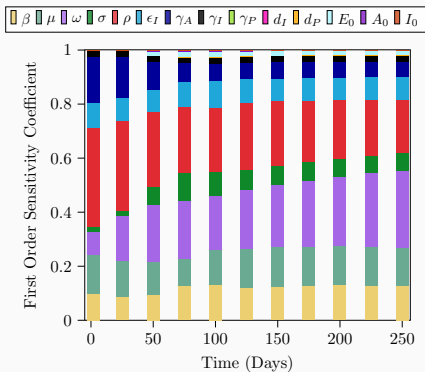



Figura 6: Evolução do $\mathcal{R}(t)$ e histograma para o dia em que $\mathcal{R}(t) = 1$.

Análise de Sensibilidade



(a) $QoI_1(t) = \mathcal{R}(t)$



(b) $QoI_2(t) = \sqrt{C(t)^2 + D(t)^2}$

Figura 7: Alterações temporais do índice de sensibilidade de primeira ordem.

Cenários hipotéticos: alterando as medidas de distanciamento social


Taxa de remoção

$$\omega_r = \omega e^{-\lambda(t-t_d)}$$

Constante de decaimento: $\lambda = \ln 2 / t_{1/2}$

Dia da implementação: $t_d = 100$ dias


COVID-19




Cenários considerados

- Relaxamento brusco, com meia-vida de $t_{1/2} = 0.1$ dias
- Relaxamento gradual, com meia-vida de $t_{1/2} = 15$ dias
- Situação original, com taxa de remoção ω


Cenários hipotéticos: alterando as medidas de distanciamento social em $t_d = 100$ dias




(a) Estimativas dos valores médios de casos confirmados.



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



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



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

Cenários hipotéticos: alterando as medidas de distanciamento social em $t_d = 100$ dias




Figura 8: Evolução do $\mathcal{R}(t)$ in BR. Linhas pontilhadas indicam intervalo de credibilidade de 95% em torno de $\mathcal{R}(t) = 1$.

Um outro cenário hipotético (mais crítico!)

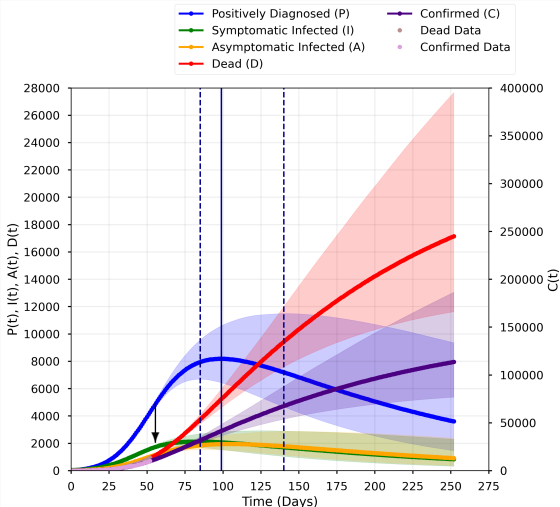


Figura 9: Predições considerando liberação da quarentena com $t_{1/2} = 20$ dias realizada 20 dias antes da ocorrência do pico dos casos infectados ativos. Situação em 22/06/2020: 97572 confirmados e 8933 óbitos acumulados (semana 26).

SEAIRPD-Q

- Desenvolvemos um modelo SEIRD generalizado que leva em conta quarentena;
- Caso de estudo: COVID-19 no RJ;
- Dados reais e incertezas foram consideradas.

Sumário dos resultados

- AS identificou os parâmetros ω e ρ como os mais influentes;
- Resultados apontam para a necessidade de manter as políticas de distanciamento social; tanto o dia quanto a forma de relaxamento da quarentena devem ser cuidadosamente planejados;
- AS aponta a importância de uma política de testagem mais ampla, capaz de identificar os infectados sintomáticos e assintomáticos;
- As incertezas nas previsões aumentam de forma significativa ao longo do tempo evidenciando a importância de “alimentar” continuamente o modelo.

Perspectivas

- Incorporação das novas informações sobre subnotificação e percentual de assintomáticos;
- Desenvolvimento de novos modelos (extensões/simplificações - família de modelos) e de procedimentos sistemáticos de seleção de modelos;
- Extensão para heterogeneidade espacial: modelagem de metapopulações e em redes complexas.

Referências



Diego T. Volpato, Anna C. M. Resende, Lucas dos Anjos, João V. O. Silva, Claudia M. Dias, Regina C. Almeida, and Sandra M. C. Malta.

Spreading of COVID-19 in Brazil: Impacts and uncertainties in social distancing strategies.

medRxiv:10.1101/2020.05.30.20117283, p. 1–34, 2020.



Diego T. Volpato, Anna C. M. Resende, Lucas dos Anjos, João V. O. Silva, Claudia M. Dias, Regina C. Almeida e Sandra M. C. Malta.

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

SciELOPreprints:10.1590/SciELOPreprints.595, p. 1–13, 2020.



Diego T. Volpato, Anna C. M. Resende, Lucas dos Anjos, João V. O. Silva, Claudia M. Dias, Regina C. Almeida, and Sandra M. C. Malta.

pydemic: Scripts for the BR/RJ social distancing study.

Zenodo:10.5281/zenodo.3865004