

# Spatiotemporal Epidemic Modelling of COVID19 using Mobile Phone Data

Sergio Oliva

Departamento de Matemática Aplicada  
Instituto de Matemática e Estatística  
Universidade de São Paulo

Agosto 2020

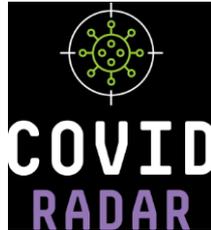
# Objetivo

Apresentar algumas ações do grupo do Departamento de Matemática Aplicada e de outros grupos que concentraram seus estudos na ajuda ao combate à pandemia.



# Esforço Coletivo

Se juntaram a este esforço várias instituições privadas e pessoas destas instituições.

The logo for 'inloco' is written in a bold, dark blue, lowercase sans-serif font.

# Reconhecimento

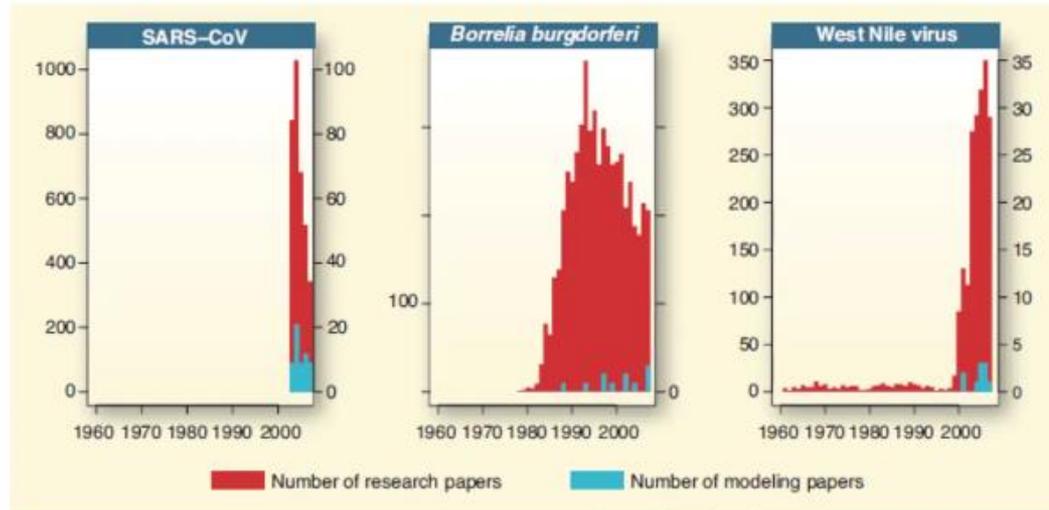
Instituições públicas reconhecendo e olhando o esforço desta miríade de trabalhos. Grupo participando do centro de contingenciamento, pela SDE/SP do grupo de modelagem e do SIMI-SP.



COVID-19 BRASIL

# Reconhecimento

Interesse acadêmico nas crises é comum.



**Fig. 3.** Temporal profiles of total research effort (red) and modeling effort (blue) for recently emerged zoonoses. Figure panels have different y-axis scaling, but in each instance, the scaling for number of modeling studies (right axis) is 1/10th that for the total number of research papers (left axis).

# Nossa contribuição

Heterogeneidade espacial dos modelos epidemiológicos, dinâmica, desafios e possibilidades.

<https://www.ime.usp.br/~pedrosp/covid19/>

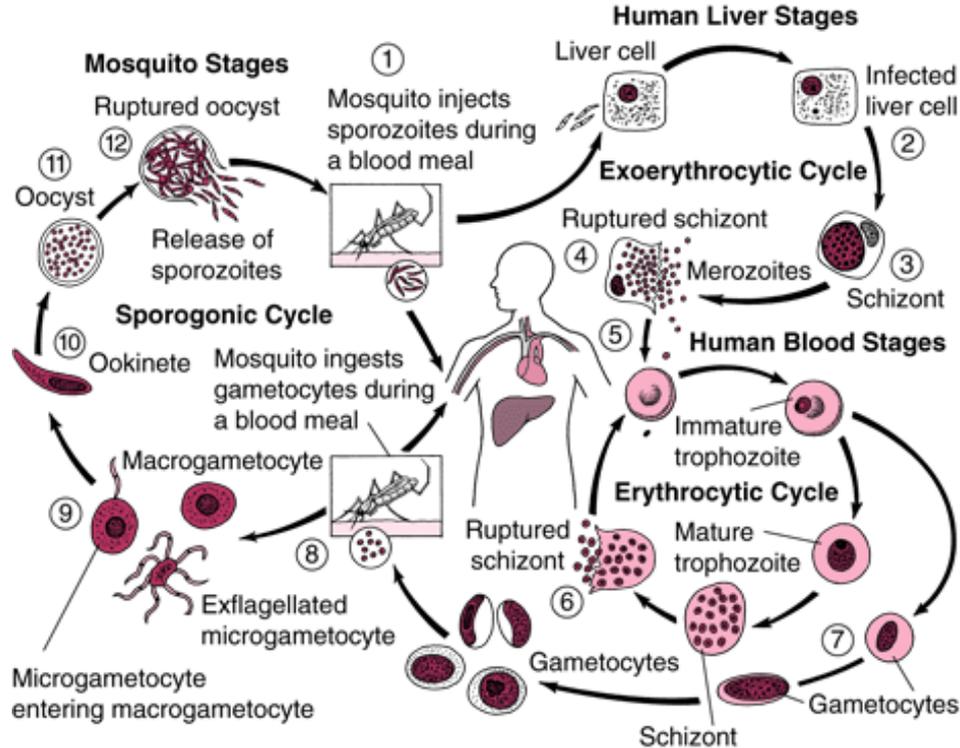
- ✓ Nos anos 60, a melhoria das infraestruturas sanitárias, aperfeiçoamento de antibióticos e programas de vacinação criaram uma certeza que doenças infecciosas desapareceriam.
- ✓ Os países desenvolvidos deram maior atenção a doenças crônicas como cardiovasculares e câncer. Mas as doenças infecciosas continuaram a ser fonte de sofrimento em outros países.
- ✓ Agentes de doenças infecciosas se adaptam e evoluem.
- ✓ Doenças infecciosas se espalham e atingem proporções globais.



Figure 2: The worldwide air transportation network. More than 3 billion passengers travel on this network each year, on flights connecting approx. 4000 airports. The heterogeneity of the network is reflected by the flux of individuals between nodes, ranging from a few to more than 10,000 passengers per day between nodes.

Brockmann, et al, Human Mobility and Spatial Disease Dynamics, diffusion-fundamentals.org 11 (2009) 2, pp 1-27

# Doenças são processos complexos



[http://www.merckmanuals.com/professional/infectious\\_diseases/extraintestinal\\_protozoa/malaria.html](http://www.merckmanuals.com/professional/infectious_diseases/extraintestinal_protozoa/malaria.html)

# Modelagem

- ✓ Idealmente descrever a dinâmica e desenhar cenários
- ✓ Simplificar essa complexidade em características aplicadas a alguns estados da doença.

Modelo pode ser descrito como “uma maneira conveniente de representar algo importante”

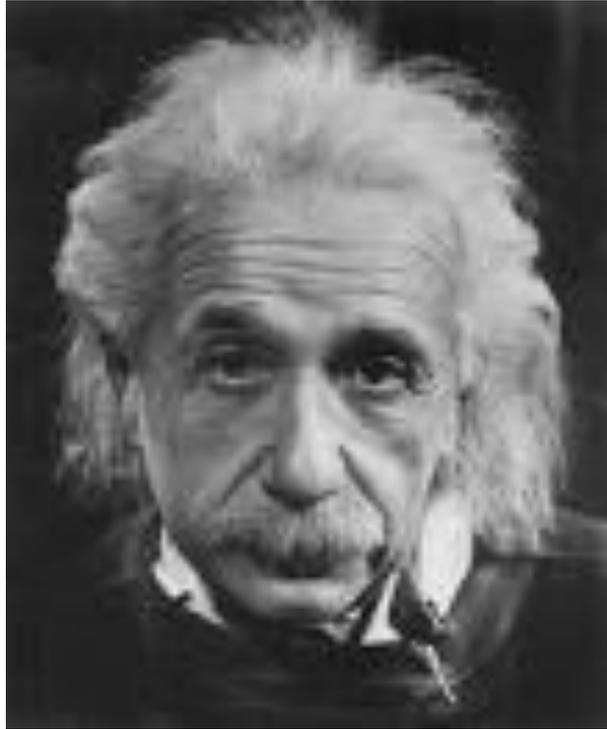
# Modelagem

- ✓ Idealmente descrever a dinâmica e desenhar cenários
- ✓ Simplificar essa complexidade em características aplicadas a alguns estados da doença.

## Forecasting vs Projection Models

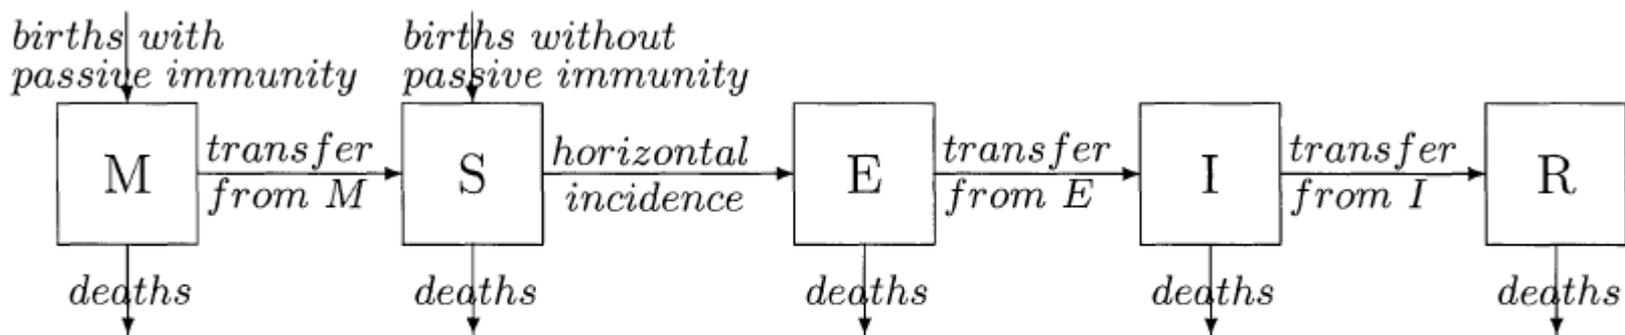
- Forecasting: prever antes de acontecer;
- Projection: o que aconteceria se...

# Modelagem

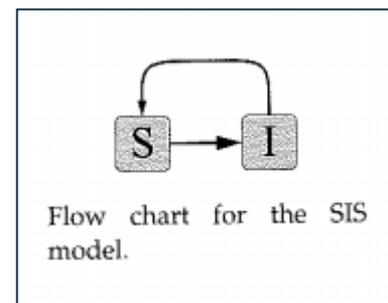
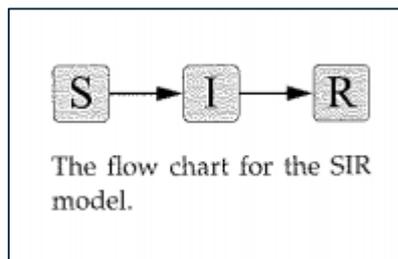
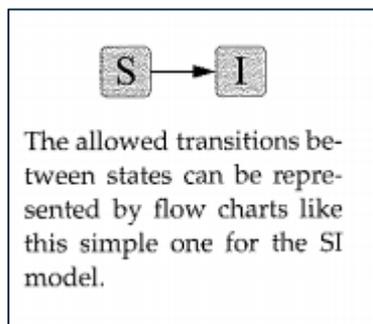


**Models must be kept  
simple, but not  
simpler...**

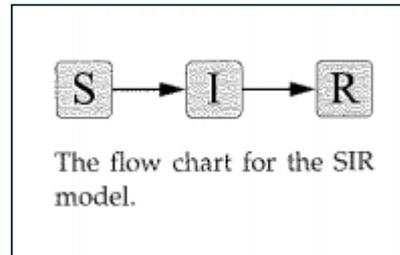
*Albert Einstein*



**Fig. 1** The general transfer diagram for the MSEIR model with the passively immune class  $M$ , the susceptible class  $S$ , the exposed class  $E$ , the infective class  $I$ , and the recovered class  $R$ .



- $S(t)$  is the number of susceptibles at time  $t$ ,
- $I(t)$  is the number of infectives,
- $N$  is the total population size,
- $s(t) = S(t)/N$  and  $i(t) = I(t)/N$  are the susceptible and infectious fractions,
- $\beta$  is the average number of contacts sufficient for transmission
- $\beta I/N = \beta i$  is the average number of contacts with infectives per unit time
- $(\beta I/N)S = \beta N i s$  is the number of new cases per unit time
- $1/\gamma$  Average infectious period



## The Reproductive Rate of Infections

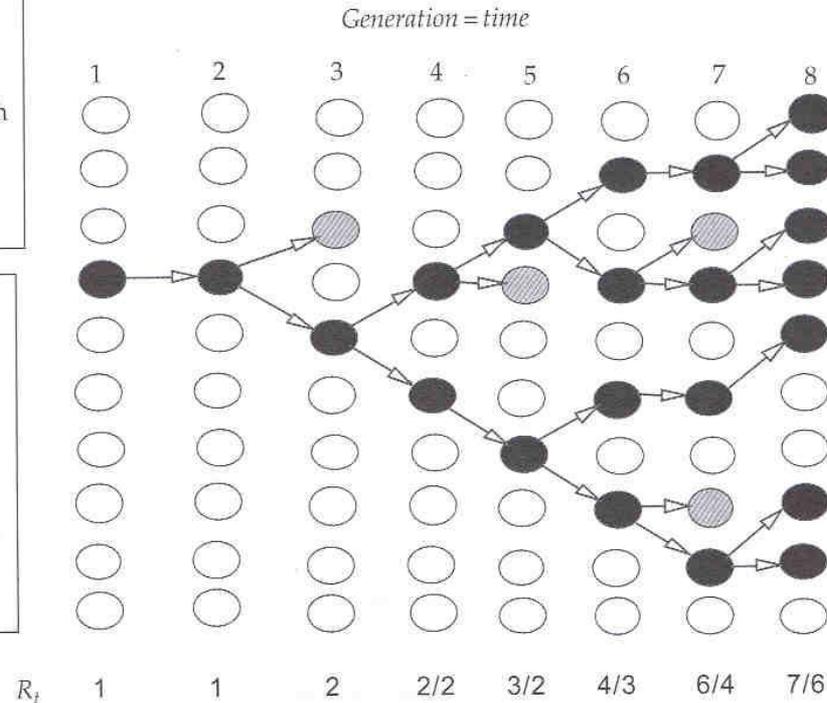
The Basic Reproductive Number,  $R_0$ , is the number of secondary infections produced by a single infectee during his/hers entire infectiousness period in an entirely susceptible population.

$R_0$  Basic reproduction number.  
Average number of secondary cases generated by 1 primary case in a susceptible population

$R_t$  Effective reproduction number.  
Number of infections caused by each new case occurring at time,  $t$ . For illustrative purposes, we use a discrete generation model.

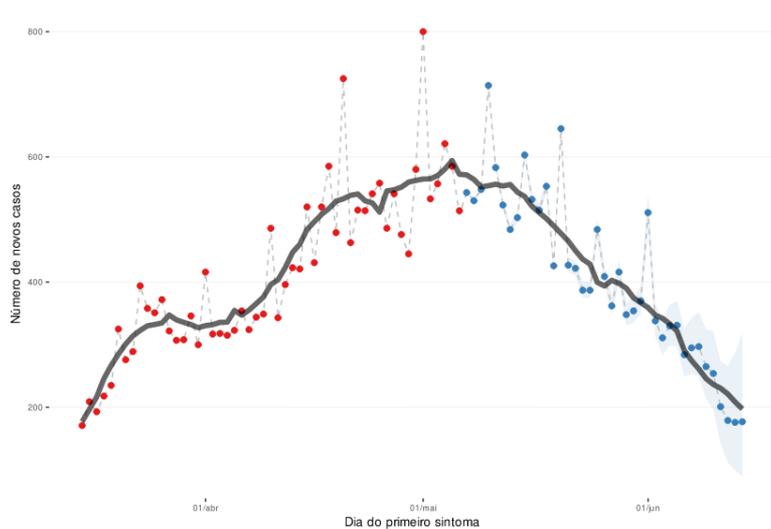
- The key determinant of incidence and prevalence of infection is the basic reproductive number  $R_0$ .
- Many factors determine its magnitude, including those that influence the typical course of infection in the patient and those that determine transmission between people.

### Chains of transmission between hosts

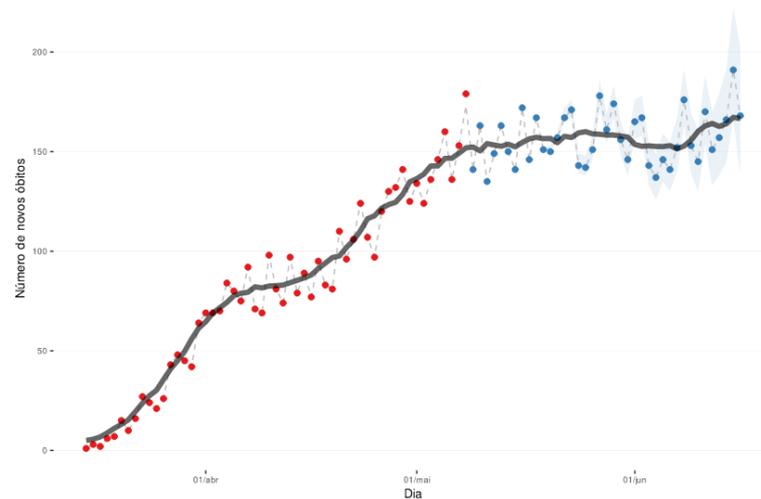


**Figure 10.6** Diagrammatic representation of chains of transmission. The speed of spread is determined by the case reproductive number  $R_0$ .

# Grande São Paulo

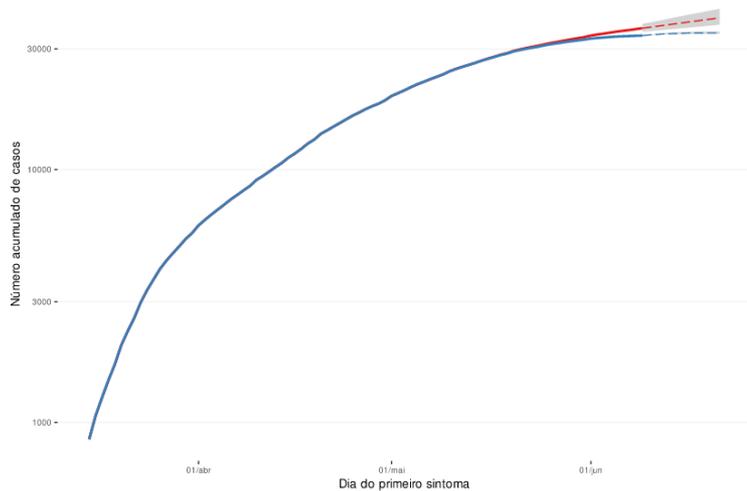


- Pontos em vermelho: casos notificados há mais de 40 dias.
- Pontos em azul: casos diários estimados através da correção do atraso entre a data dos primeiros sintomas e a notificação.
- Linha preta é a tendência estimada, com média móvel para um período de 10 dias.

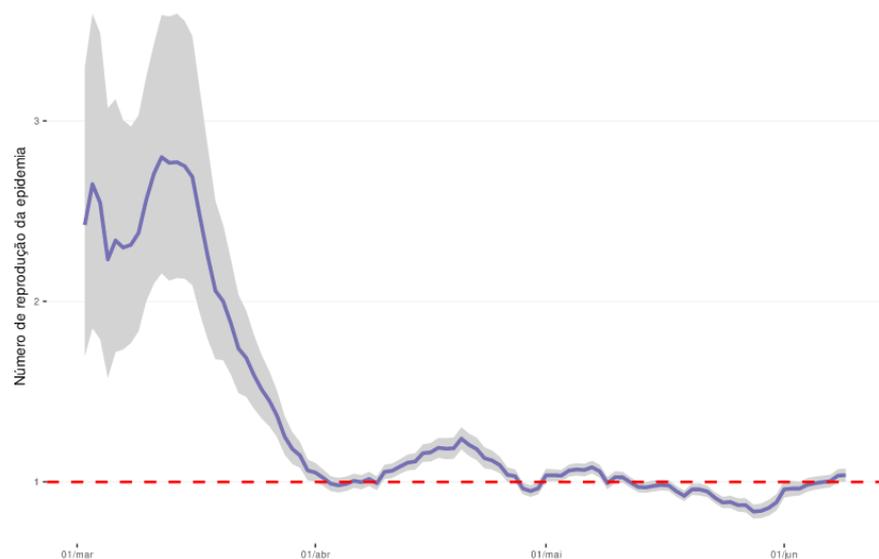


- Pontos em vermelho: casos notificados há mais de 40 dias.
- Pontos em azul: casos diários estimados através da correção do atraso entre a data dos primeiros sintomas e a notificação.
- A linha preta é a tendência estimada, com média móvel de 10 dias.

# Grande São Paulo

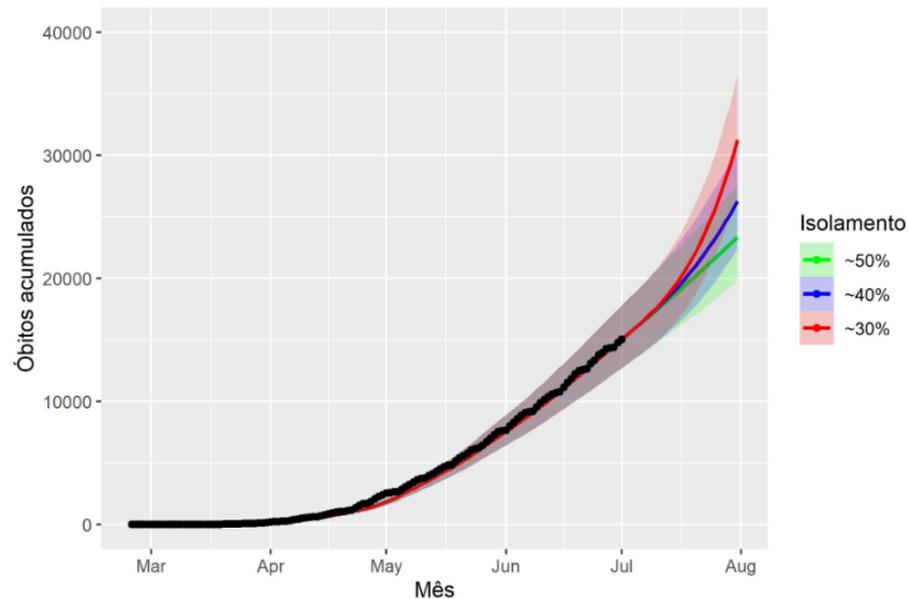
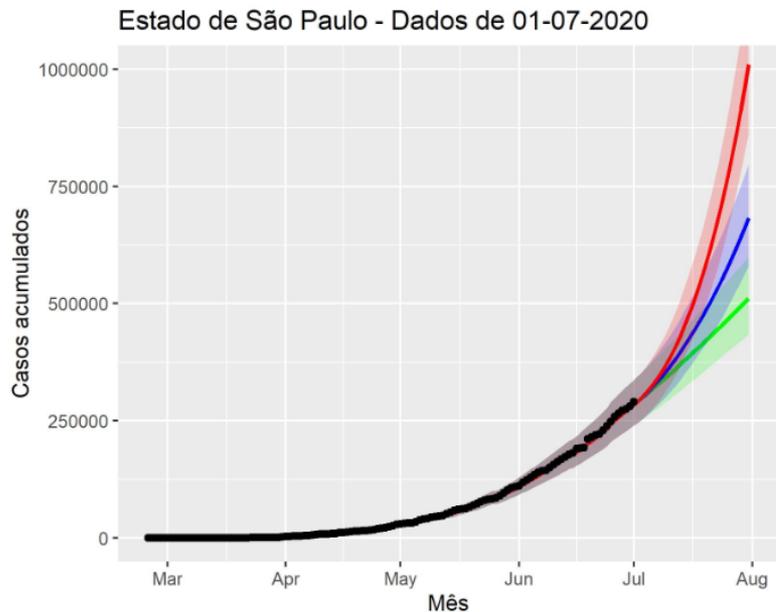


- tracejados da linha vermelha são as projeções(últimos 2 dias e próximos 5 dias)( 95% de confiança).
- linha azul contínua indica o número de casos observados acumulados até a última data.
- linha vermelha contínua indicam o número de casos estimados acumulados, corrigindo o tempo entre os primeiros sintomas e a notificação. (Log)



Previsões do Observatório Covid-19 BR: <https://covid19br.github.io/>

# Estado de São Paulo



Previsões Eduardo Massad e Markus Amaku

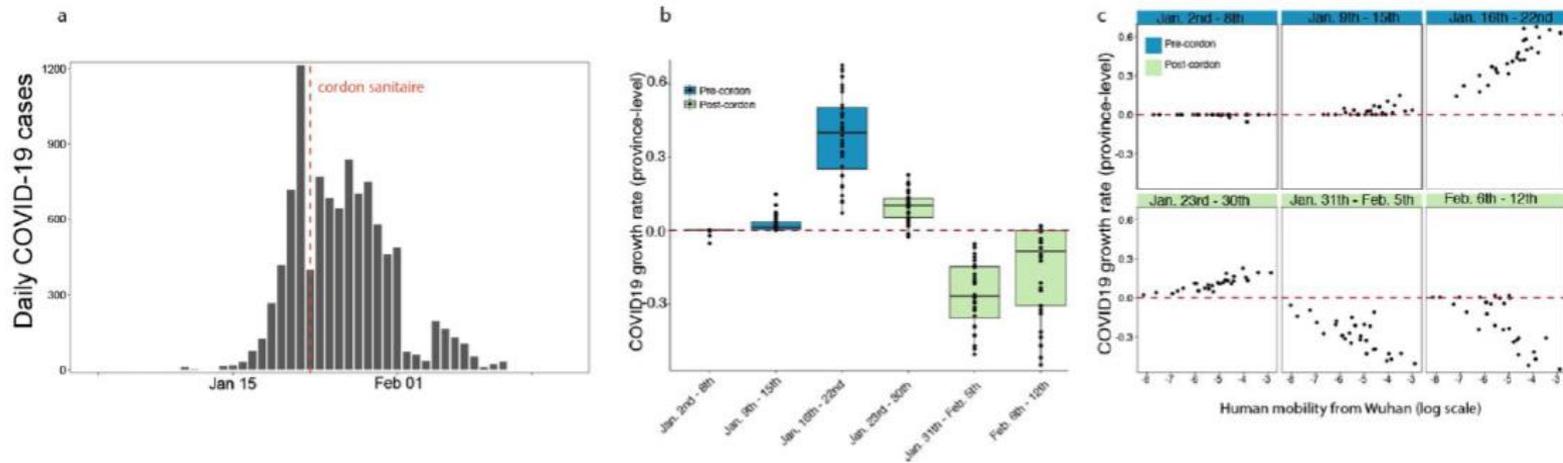


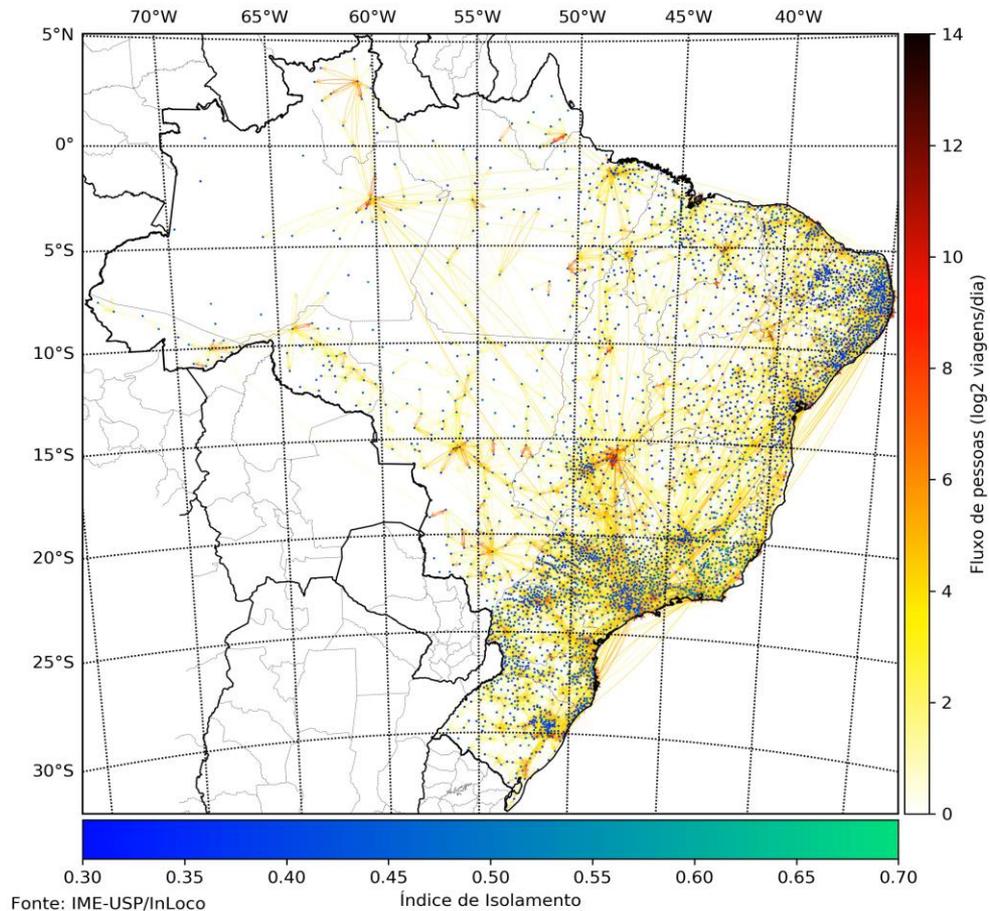
Fig. 3. Human mobility explains early epidemic growth rate in China. (a) Daily counts of cases in China. (b) Time series of province-level growth rates of the COVID-19 epidemic in China. Estimates of the growth rate were obtained by performing a time-series analysis using mixed-effect model of lagged, log linear daily case counts in each province (**Materials and Methods**). Above the red line are positive growth rates and below are growth rates are negative rates. Blue indicates dates before the implementation of the cordon sanitaire and green after. (c) Relationship between growth rate and human mobility at different times of the epidemic. Blue indicates before the implementation of the cordon sanitaire and green after.

Cite as: M. U. G. Kraemer *et al.*, *Science*  
10.1126/science.abb4218 (2020).

# **Espalhamento espacial**

## **Redes**

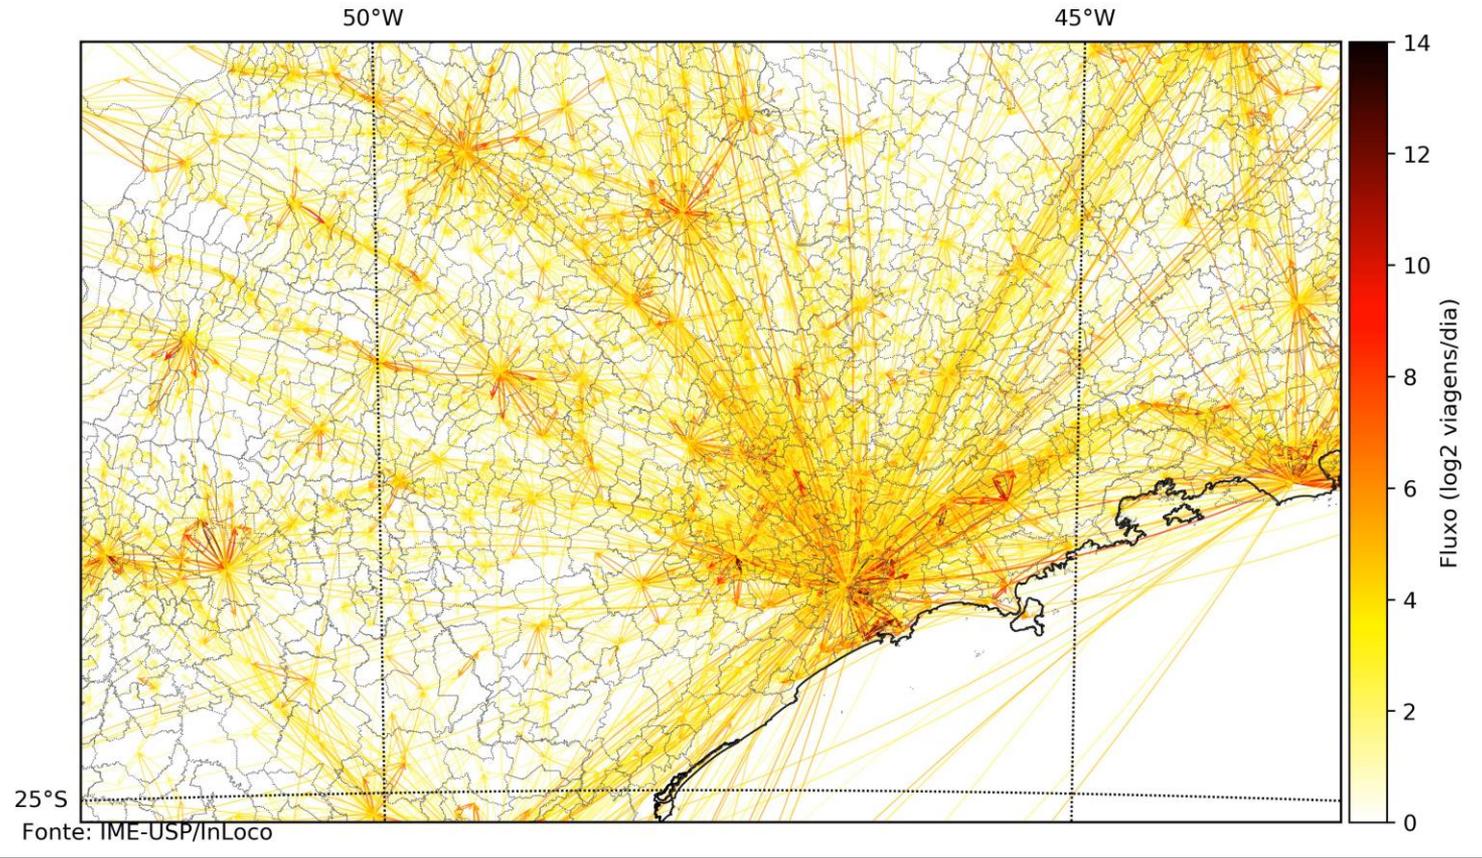
# Brasil Municip Network 2020-03-01 Sun



Fonte: IME-USP/InLoco

Índice de Isolamento

# Brasil Municip Network Zoom SP 2020-03-01 Sun

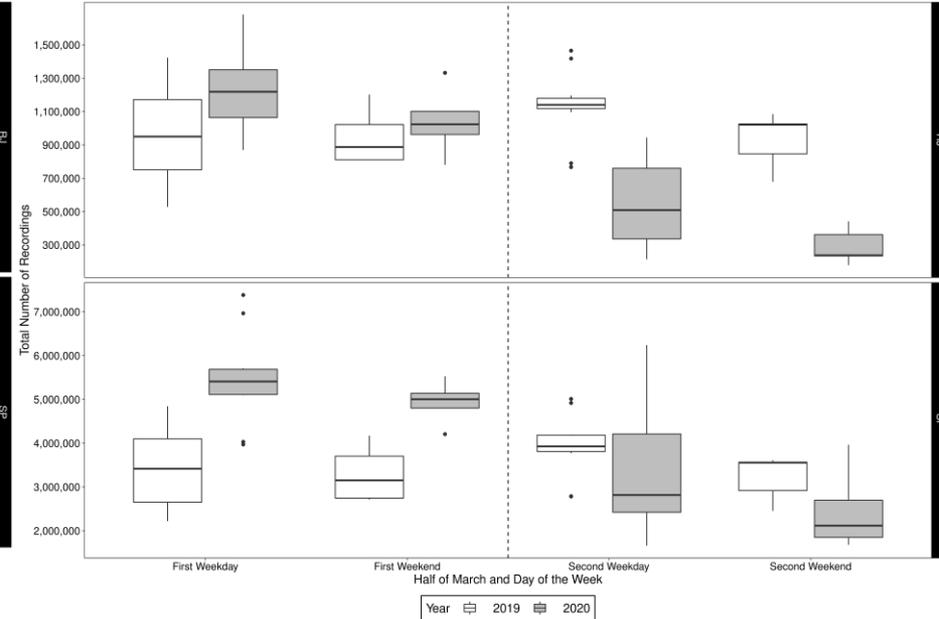
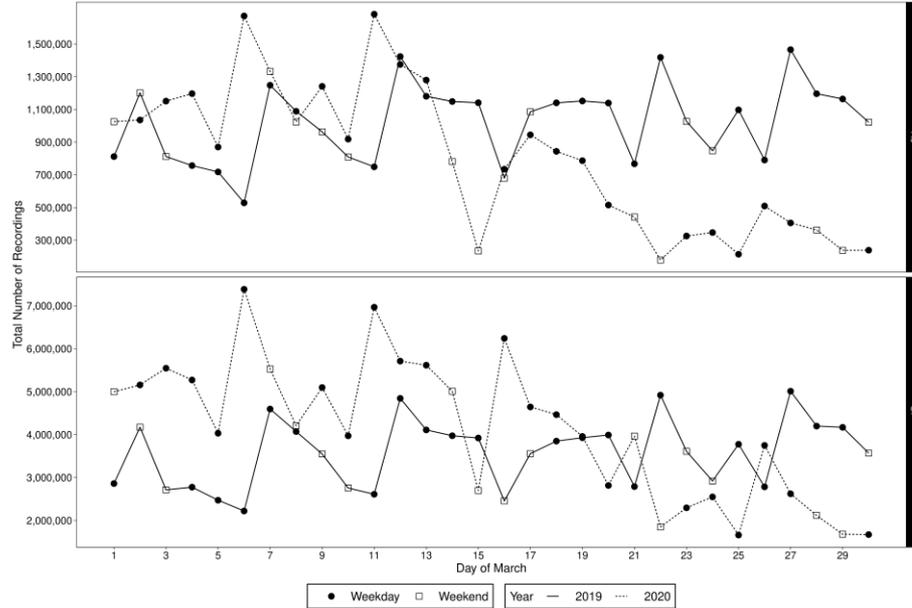


## O que são esses dados?

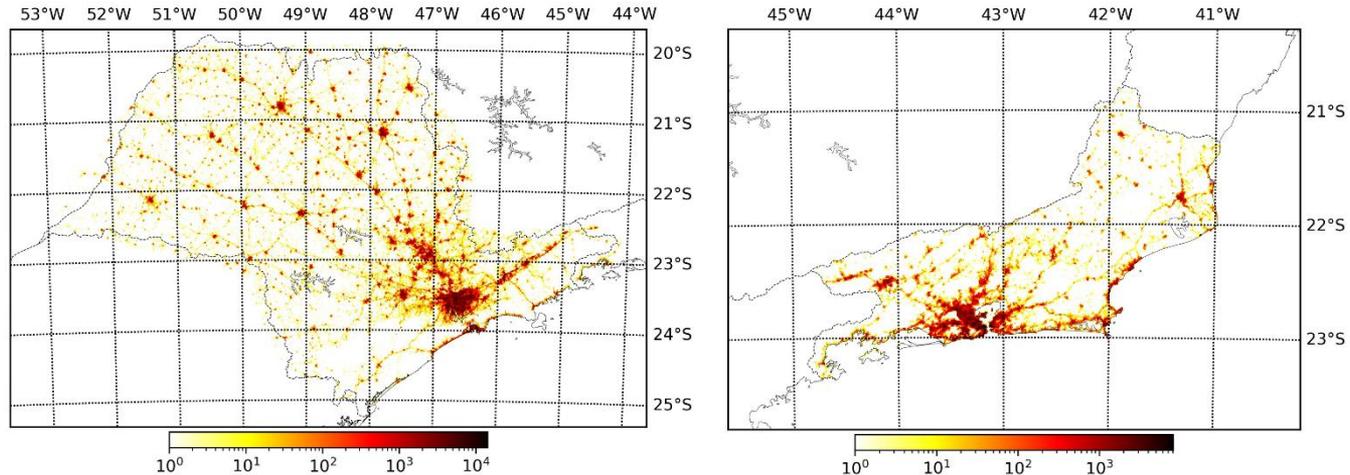
- Dados de geolocalização anonimizados de celulares da empresa InLoco
- Empresa que fornece SKD para celulares, com uma base de mais de 60 milhões de celulares
- São bilhões de visitas registradas
- Nos fornece a localização dos celulares que se movimentaram (origem e o próximo registro).

State	Year	Day Week	Mean	SD	Min	1 <sup>st</sup> Quart.	Median	3 <sup>rd</sup> Quart.	Max
RJ	2019	Weekday	1,053,615	259,721	528,805	790,609	1,140,444	1,180,351	1,465,666
		Weekend	938,472	163,672	679,678	811,883	962,988	1,026,558	1,201,777
	2020	Weekday	870,920	445,958	214,521	509,431	870,189	1,196,752	1,682,386
		Weekend	624,417	425,258	179,309	238,466	442,211	1,023,705	1,332,701
SP	2019	Weekday	3,708,276	850,839	2,221,510	2,790,522	3,927,577	4,169,805	5,011,449
		Weekend	3,256,169	563,222	2,456,231	2,756,478	3,550,141	3,569,211	4,172,801
	2020	Weekday	4,353,782	1,652,625	1,661,284	2,816,090	4,465,741	5,545,852	7,384,012
		Weekend	3,561,949	1,495,902	1,681,135	2,118,311	3,964,115	4,999,465	5,527,734

# O que são esses dados?

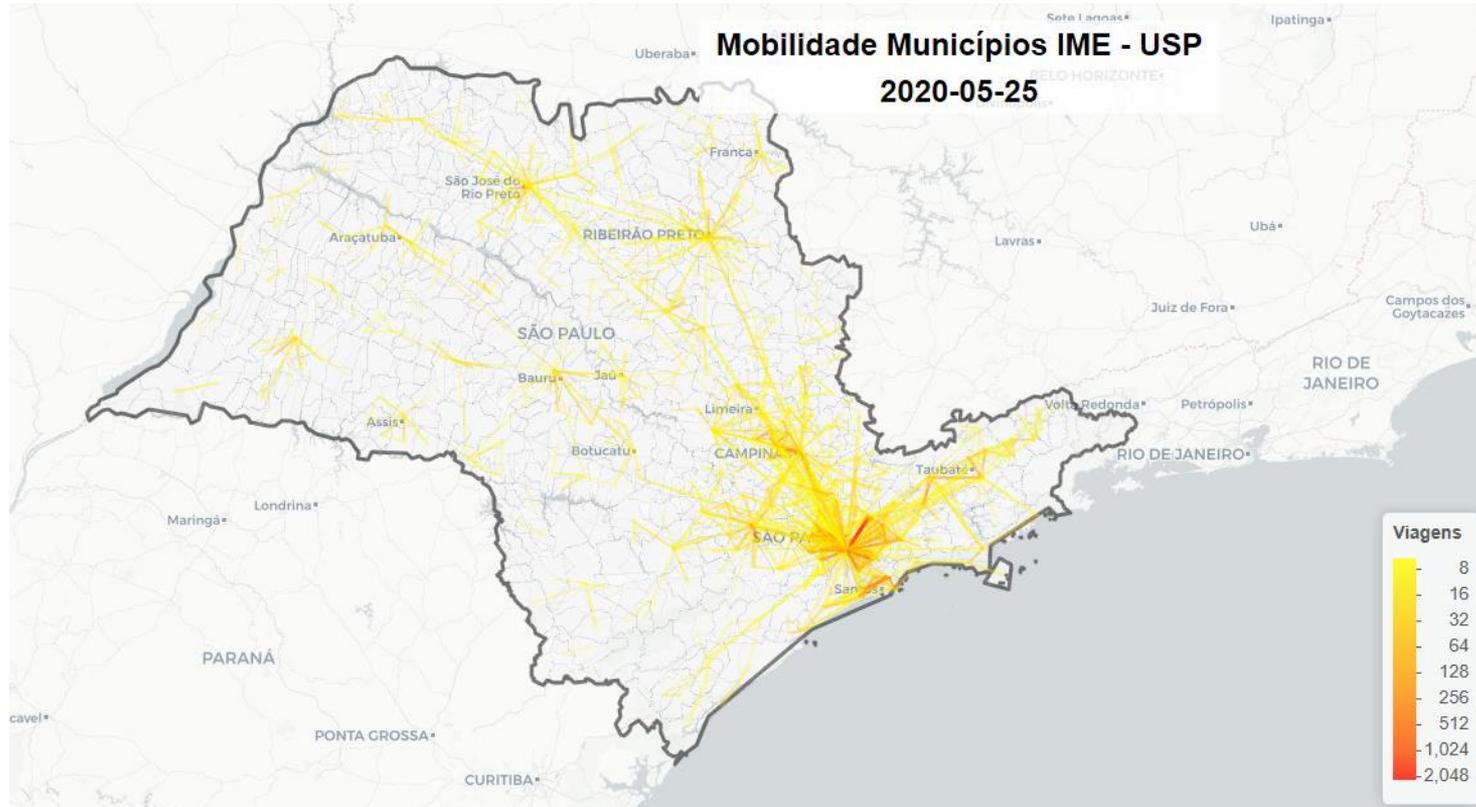


# O que são esses dados?



Typical distribution of the location of app usage in one day for the states of São Paulo (left) and Rio de Janeiro (right) considering a resolution of 0.01 degree on each geographical coordinate. This data refers to March 1<sup>st</sup>, 2020 and the color represents the number of recordings, first or subsequent, in each location.

# O que são esses dados?



Diego Marcondes

# O que são esses dados?

- Os dados indicam movimento da região A para B
- Calcular a proporção que sai de A para cada outra região em um dia (a proporção é sobre o número total de registros de A ( $\hat{R}_A^n$ ))
- A proporção dos que não se movimentaram de A é obtido a partir do número de registros que começaram em A neste dia e ainda estavam em A no segundo registro.
- Estas proporções formam a matriz de transição ( $\hat{p}_{AB}^n$ ).
- Escolhemos como região as cidades.

# Um primeiro trabalho

## Março 2020

# Compartmented Model

SIS

(S) Susceptible

(I) Infected

$N$  : Population size



$$S' = -\alpha \frac{SI}{N} + \beta I$$

$$I' = \alpha \frac{SI}{N} - \beta I$$

# Compartmented Model

SIS

(S) Susceptible

(I) Infected

$N$  : Population size

$$\frac{dj}{dt} = \alpha(1-j)j - \beta j$$

where

$$j = \frac{I}{N} \text{ and } s = \frac{S}{N} \text{ (densities)}$$

and

$$R_0 = \frac{\alpha}{\beta} > 1 \Rightarrow j^s = 1 - \frac{1}{R_0}$$

# Compartmented Model

SIS

(S) Susceptible

(I) Infected

$N$  : Population size

$$\frac{dj}{dt} = \alpha(1-j)j - \beta j$$

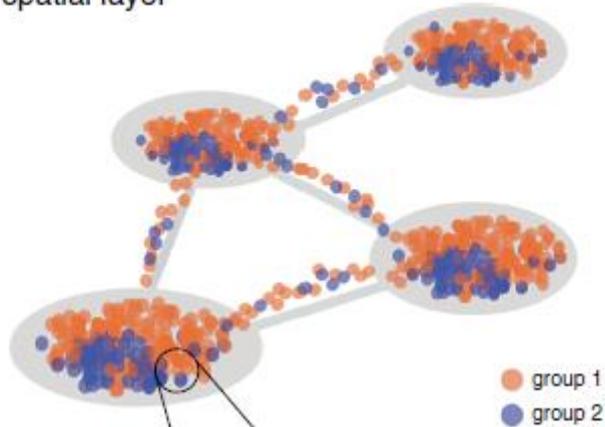
where

$$j = \frac{I}{N} \text{ and } s = \frac{S}{N} \text{ (densities)}$$

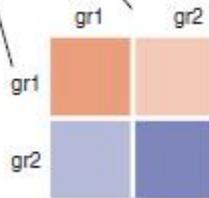
and

$$R_0 = \frac{\alpha}{\beta} > 1 \Rightarrow j^s = 1 - \frac{1}{R_0} \text{ stable}$$

A spatial layer



B social layer



**Figure 1 Scheme of the model.** (A) The spatial layer, based on the metapopulation approach, describes the space structure and the mobility of individuals. (B) The social layer describes the contact structure within each subpopulation.

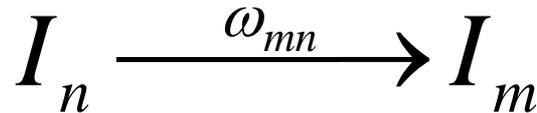
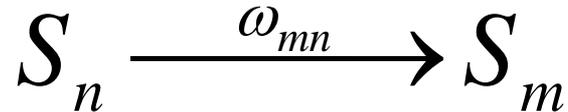
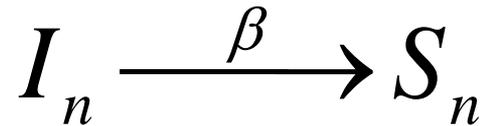
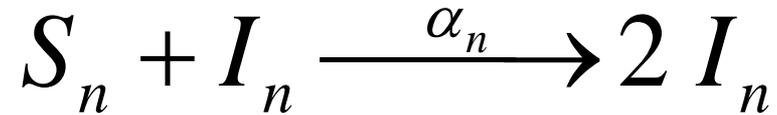
Spatially compact area  $\Omega_n$

Total Pop:  $N_n(t) = \Omega_n \langle u(x, t) \rangle$

**Mobility**

exchange of each individual between the discrete set of communities.

# SIS + Metapopulation



# SIS + Metapopulation

$$\frac{dS_n}{dt} = -\alpha_n \frac{S_n I_n}{N_n} + \beta I_n + \sum_{m \neq n} [\omega_{nm} S_m - \omega_{mn} S_n]$$

$$\frac{dI_n}{dt} = \alpha_n \frac{S_n I_n}{N_n} - \beta I_n + \sum_{m \neq n} [\omega_{nm} I_m - \omega_{mn} I_n]$$

# SIS + Metapopulation

$$\frac{dI_i}{dt}(t) = (1+r)I_i(t) \left( \frac{N_i - I_i(t)}{N_i} \right) + s \left[ \sum_{j \neq i} \omega_{ji}(t) I_j(t) - \sum_{j \neq i} \omega_{ij}(t) I_i(t) \right]$$

- $r$  é a taxa de transmissão em cada região
- $s$  é um parâmetro livre para corrigir a sub ou super estimacão da mobilidade
- $N_i$  é a população da cidade  $i$

# SIS + Metapopulation

$$\frac{dI_i}{dt}(t) = (1+r)I_i(t) \left( \frac{N_i - I_i(t)}{N_i} \right) + s \left[ \sum_{j \neq i} \omega_{ji}(t) I_j(t) - \sum_{j \neq i} \omega_{ij}(t) I_i(t) \right]$$

Como estimar a movimentação?

- $r$  é a taxa de transmissão em cada região
- $s$  é um parâmetro livre para corrigir a sub ou super estimação da mobilidade
- $N_i$  é a população da cidade  $i$

# SIS + Metapopulation

$$\frac{dI_i}{dt}(t) = (1+r)I_i(t) \left( \frac{N_i - I_i(t)}{N_i} \right) + s \left[ \sum_{j \neq i} \omega_{ji}(t) I_j(t) - \sum_{j \neq i} \omega_{ij}(t) I_i(t) \right]$$

Como estimar a movimentação?

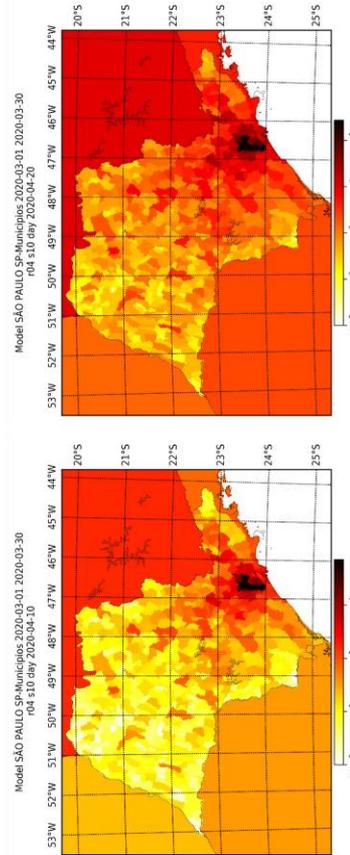
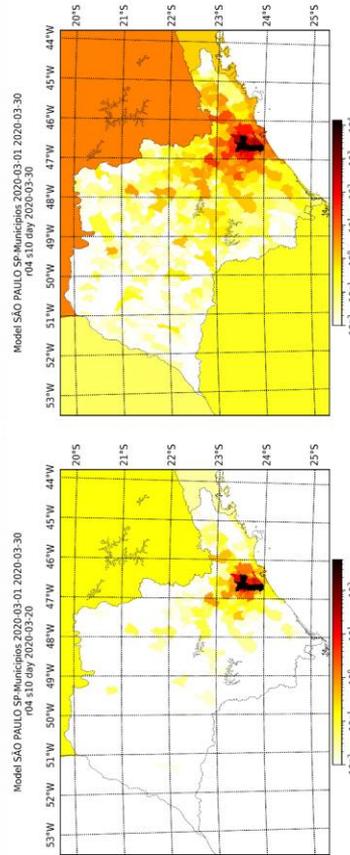
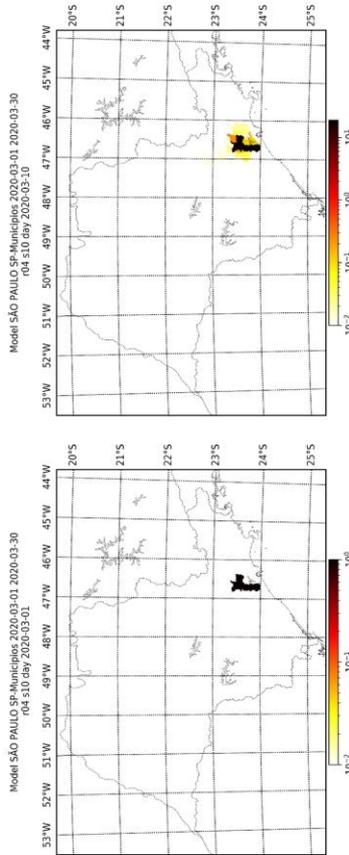
- $r = \frac{R_0}{6} = 0.4$  é a taxa de transmissão em cada região (utilizamos  $R_0=2.68$ )
- $s$  é um parâmetro livre para corrigir a sub ou super estimacão da mobilidade
- $N_i$  é a população da cidade  $i$
- $\omega_{ji}(t)$  é uma medida de movimentação da cidade  $j$  para a cidade  $i$
- $\omega_{ji}(t) = \frac{\hat{p}_{ji} \hat{R}_j^n}{N_j}$ , para  $24(n-1) \leq t < 24n$

# Resultados

City	Year	Mean	SD	Min	1st Quart.	Median	3rd Quart.	Max
Guarulhos	2019	648	-	648	648	648	648	648
Guarulhos	2020	648	-	648	648	648	648	648
Osasco	2019	647	-	647	647	647	647	647
Osasco	2020	647	-	647	647	647	647	647
Santo André	2020	646	-	646	646	646	646	646
Santo André	2019	646	0,30	645	646	646	646	646
Taboão da Serra	2019	645	0,30	645	645	645	645	646
Taboão da Serra	2020	645	-	645	645	645	645	645

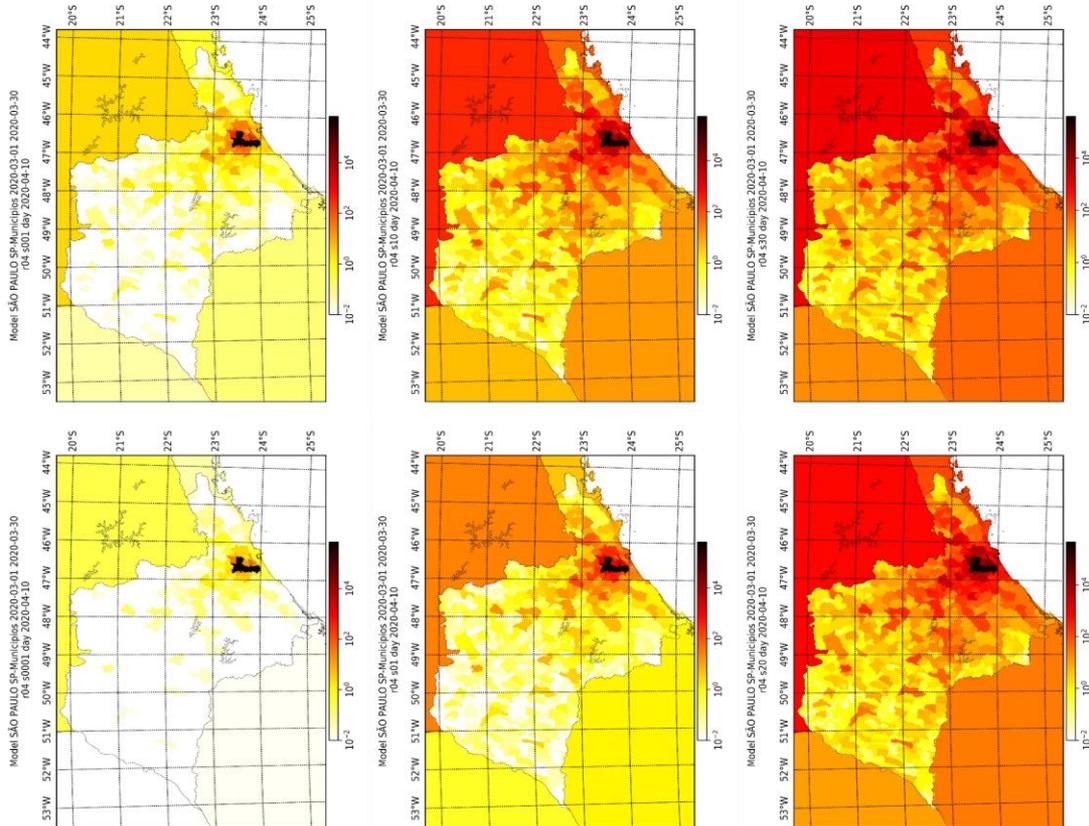
Descriptive statistics of the rank of the proportion of movement out of São Paulo capital city in the days of March 2019 and March 2020.

# Resultados



Resultados da simulação para o número de infectados em diferentes dias de março e abril, com  $s=1$ .

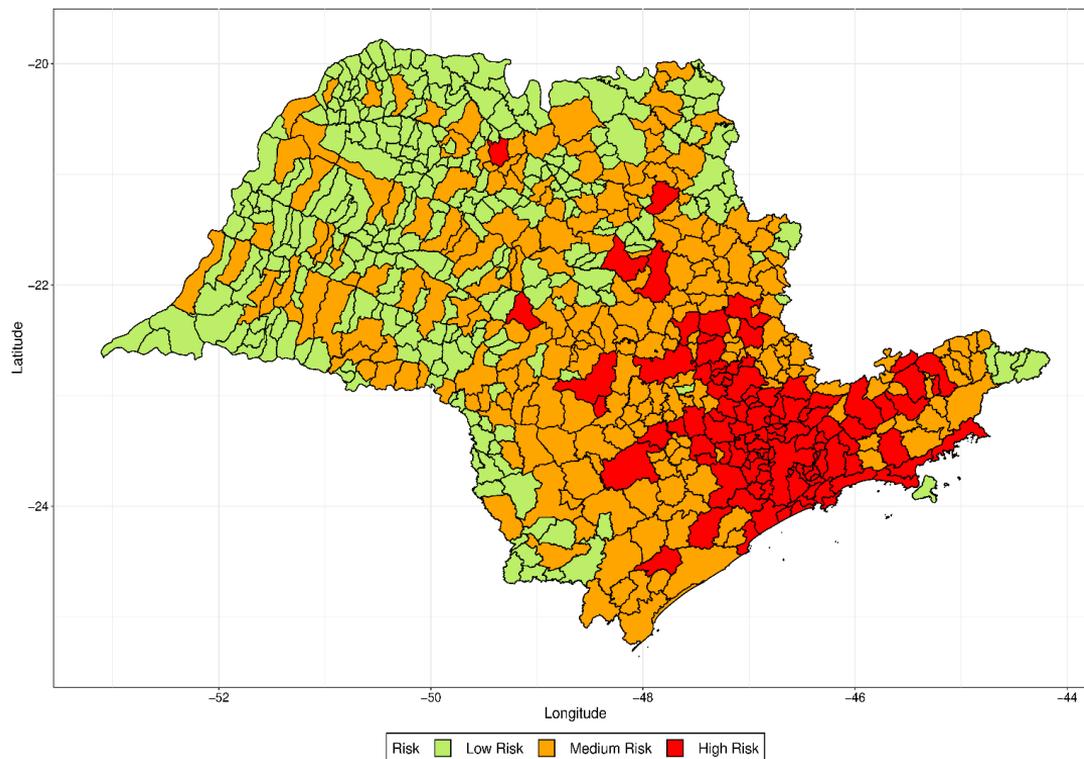
# Resultados



Resultados da simulação para o número de infectados em 10/4 com  $s=0.0001$  (top left),  $0.001$  (top right),  $0.1$  (mid-left),  $1.0$  (mid-right),  $2.0$  (bottom-left) and  $3.0$  (bottom-right)

# Resultados

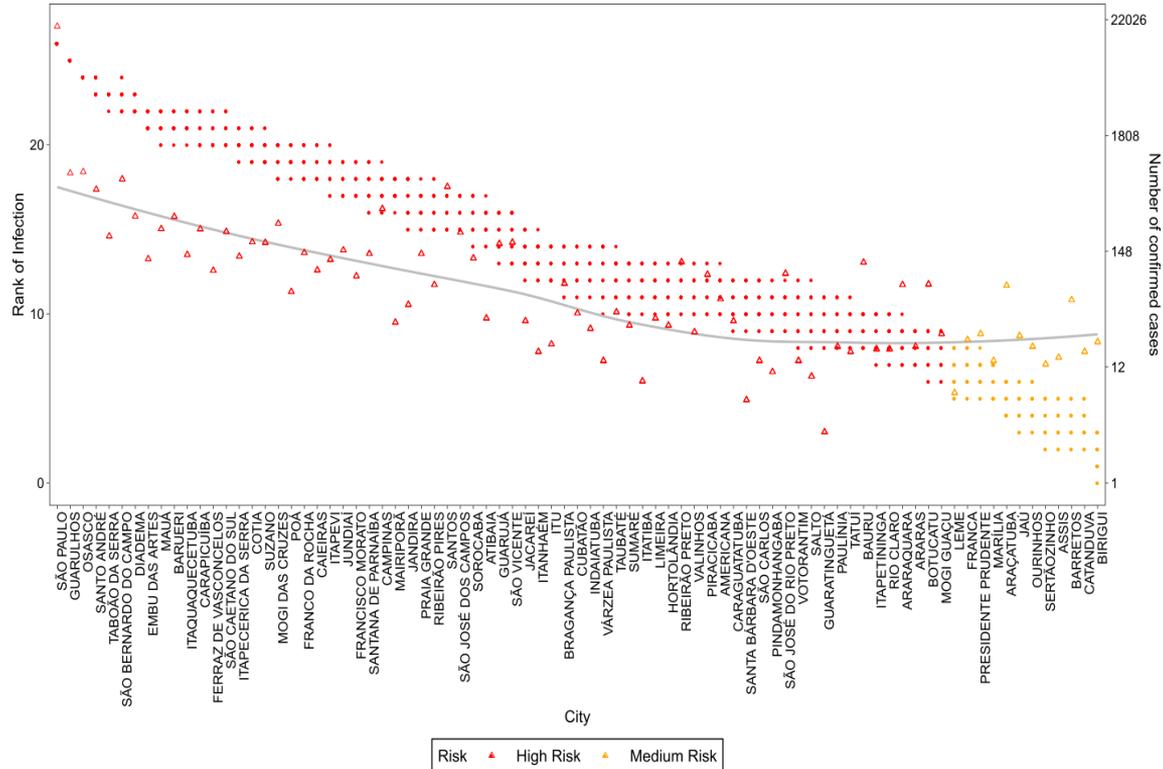
Simulamos para vários valores de  $s$ , agrupamos as cidades segundo o primeiro caso





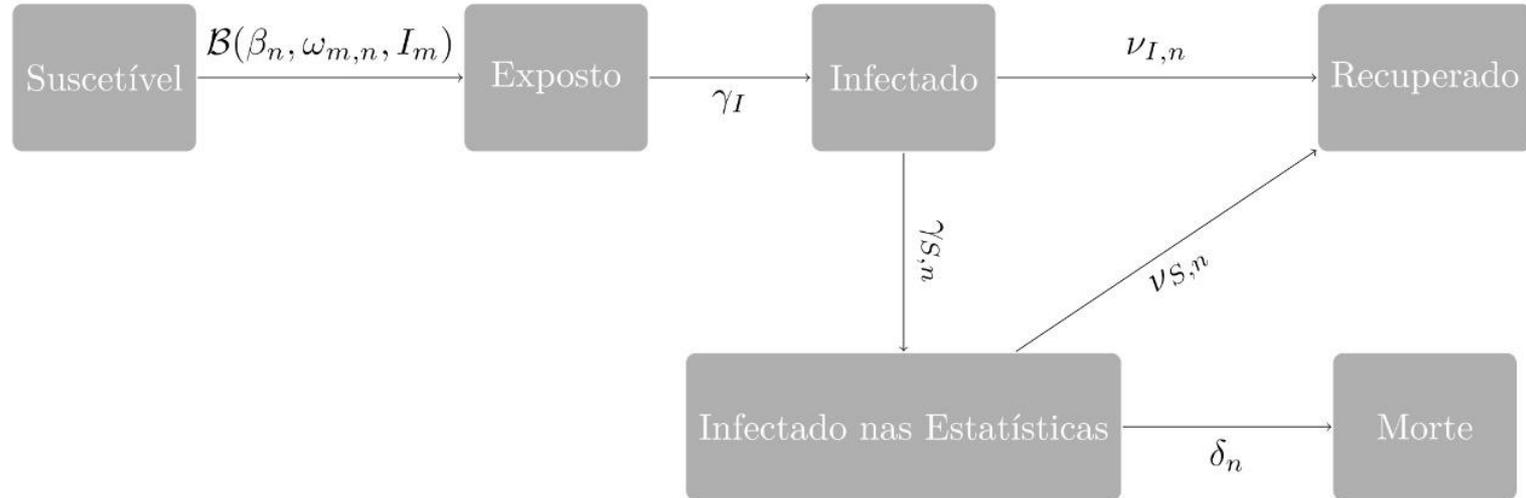
# Resultados

Agora, comparamos com os casos de 1/05



# Um Outro Resultado

Modelo de simulação robusto para modelo SEIR



Diego Marcondes et all

# Um Outro Resultado

Formally, the evolution of the number of Susceptible ( $S_n$ ), Exposed ( $E_n$ ), Infected ( $I_n$ ), Infected in Statistics ( $I_n^S$ ), Recovered ( $R_n$ ) and Dead ( $D_n$ ) by COVID-19 at each location  $n \in \mathcal{R}$  and time  $t \in \mathbb{N}$  is dictated by

$$S_n(t+1) = S_n(t) - \frac{\beta_n(t)S_n(t)}{(N_n - D_n(t))} \left( \sum_{m \neq n} \omega_{m,n}(t)I_m(t) + I_n(t) \right)$$
$$E_n(t+1) = E_n(t) - \gamma_I E_n(t) + \frac{\beta_n(t)S_n(t)}{(N_n - D_n(t))} \left( \sum_{m \neq n} \omega_{m,n}(t)I_m(t) + I_n(t) \right)$$
$$I_n(t+1) = I_n(t) - (\nu_{I,n} + \gamma_{S,n}) I_n(t) + \gamma_I E_n(t)$$
$$I_n^S(t+1) = I_n^S(t) - (\nu_{S,n} + \delta_n) I_n^S(t) + \gamma_{S,n} I_n(t)$$
$$R_n(t+1) = R_n(t) + \nu_{I,n} I_n(t) + \nu_{S,n} I_n^S(t)$$
$$D_n(t+1) = D_n(t) + \delta_n I_n^S(t)$$

# Um Outro Resultado

Formally, the evolution of the number of Susceptible ( $S_n$ ), Exposed ( $E_n$ ), Infected ( $I_n$ ), Infected in Statistics ( $I_n^S$ ), Recovered ( $R_n$ ) and Dead ( $D_n$ ) by COVID-19 at each location  $n \in \mathcal{R}$  and time  $t \in \mathbb{N}$  is dictated by

$$S_n(t+1) = S_n(t) - \frac{\beta_n(t)S_n(t)}{(N_n - D_n(t))} \left( \sum_{m \neq n} \omega_{m,n}(t)I_m(t) + I_n(t) \right)$$

$$E_n(t+1) = E_n(t) - \gamma_I E_n(t) + \frac{\beta_n(t)S_n(t)}{(N_n - D_n(t))} \left( \sum_{m \neq n} \omega_{m,n}(t)I_m(t) + I_n(t) \right)$$

$$I_n(t+1) = I_n(t) - (\nu_{I,n} + \gamma_{S,n}) I_n(t) + \gamma_I E_n(t)$$

$$I_n^S(t+1) = I_n^S(t) - (\nu_{S,n} + \delta_n) I_n^S(t) + \gamma_{S,n} I_n(t)$$

$$R_n(t+1) = R_n(t) + \nu_{I,n} I_n(t) + \nu_{S,n} I_n^S(t)$$

$$D_n(t+1) = D_n(t) + \delta_n I_n^S(t)$$

# Um Outro Resultado

In this time scale, the parameters which do not depend on time  $t$  are related to the disease average exposed time  $\tau_E$ , average time infected before getting into statistics  $\tau_S$ , average time infected before recovering without being accounted by statistics  $\tau_I$ , average time before recovering after being accounted by statistics  $\tau_{SR}$ , average time until death  $\tau_D$ , and the proportions of infected individuals accounted by statistics  $p_{S,n}$  and of deaths among them  $p_{D,n}$  in region  $n$ , as follows:

$$\gamma_I = \frac{1}{\tau_E} \quad \gamma_{S,n} = \frac{p_{S,n}}{\tau_S} \quad \nu_{I,n} = \frac{(1 - p_{S,n})}{\tau_I} \quad \nu_{S,n} = \frac{(1 - p_{D,n})}{\tau_{SR}} \quad \delta_n = \frac{p_{D,n}}{\tau_D}.$$

$$\theta := (\tau_E, \tau_I, \tau_S, \tau_{SR}, \tau_D, p_S) \in \Theta = \mathbb{R}_+^5 \times [0, 1]$$

# Um Outro Resultado

With this notation, the well fit concept is given by a fitness map

$$F : \Theta \times (\mathbb{N}^{2|\mathcal{R}|})^{T'} \rightarrow \{0, 1\}$$

which, for a  $\theta \in \Theta$  and observed evolution  $\{X(t_0 - T' + t)\}_{t=1}^{T'}$  in  $(\mathbb{N}^{2|\mathcal{R}|})^{T'}$ , attributes 1 if the evolution generated by  $\theta$  *well fit* the observed one, and attributes 0 otherwise. We will consider fitness maps of the form

$$\min \left\{ \min_{\substack{t \in \{1, \dots, T'\} \\ n \in \mathcal{R}}} \mathbf{1} \left\{ \left| I_n^S(t_0 - T' + t; \theta) - I_n^S(t_0 - T' + t) \right| \leq r_I(n) I_n^S(t_0 - T' + t) \right\} \right. \\ \left. \min_{\substack{t \in \{1, \dots, T'\} \\ n \in \mathcal{R}}} \mathbf{1} \left\{ \left| D_n(t_0 - T' + t; \theta) - D_n(t_0 - T' + t) \right| \leq r_D(n) D_n(t_0 - T' + t) \right\} \right\} \quad (2.7) \quad [$$

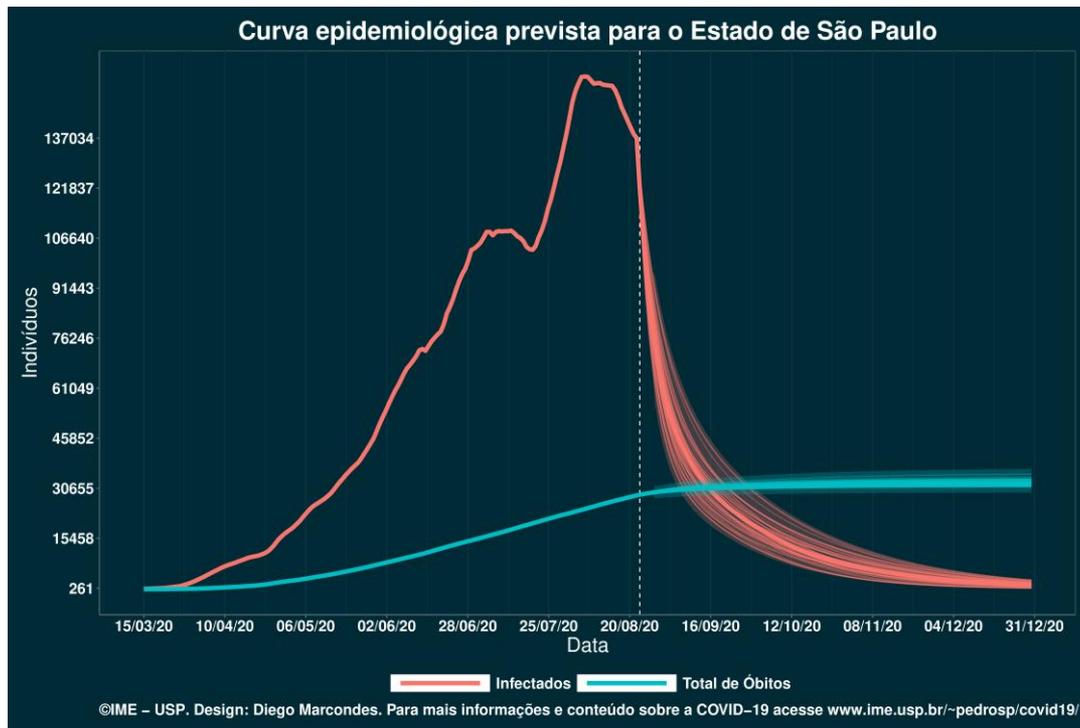
# Um Outro Resultado

TABLE 3.1. Candidate parameters.

Parameter	Candidate Values
$\tau_E$	3, 4, 5, 6
$\tau_I$	5, 6, ..., 21
$\tau_S$	7, 8, ..., 21
$\tau_{SR}$	7, 8, ..., 21
$\tau_D$	7, 8, ..., 28
$ps$	0.2, 0.167, 0.143, 0.125, 0.111, 0.1, 0.067, 0.05, 0.033, 0.025, 0.02
$s$	0.25, 0.5, 1, 1.5, 2, 2.5, 3

# Um Outro Resultado

Diego Marcondes



## Previsão para 22/09/2020

**Casos Confirmados: 912.135**  
**Melhor Cenário: 796.958**  
**Pior Cenário: 996.564**

**Mortes Confirmadas: 30.908**  
**Melhor Cenário: 28.640**  
**Pior Cenário: 33.963**

As previsões são realizadas através de Modelos SEIR Metapopulação com Mobilidade supondo que a evolução da doença se manterá da mesma forma que na semana terminando em 23/08/2020

**DISCLAIMER:** Apenas as previsões pontuais realizadas até o dia 22/09/2020 e a projeção do pico da doença devem ser considerados, para todos os DRSs e apenas para Municípios com mais de 500 casos ou 100 mortes em 23/08/2020 (os demais Municípios foram omitidos). Embora apresentadas nos gráficos, as previsões pontuais após 22/09/2020 **NÃO DEVEM SER CONSIDERADAS.**

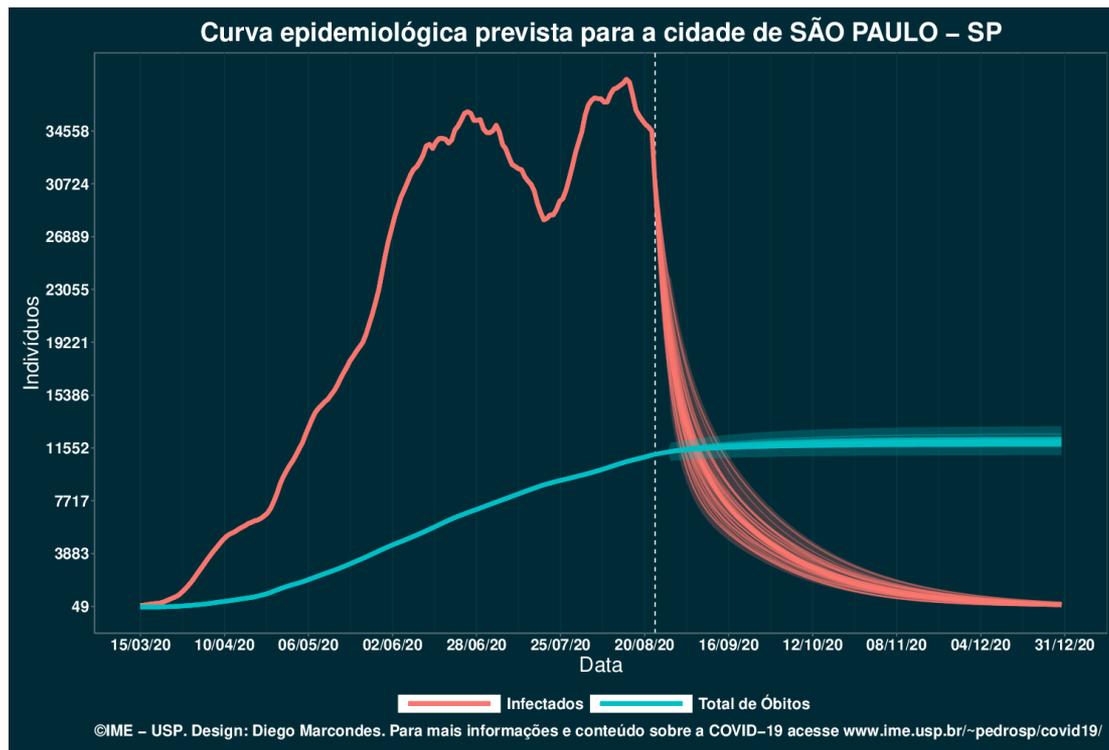
Desenvolvido por pesquisadores do **IME-USP**

Atualizado em 23/08/2020

\*Cada linha representa a previsão de um modelo. A linha grossa (mediana das previsões) e banda vermelha (melhor e pior caso) dizem respeito ao número de indivíduos que estão infectados simultaneamente na data. As linhas tracejadas são as estimativas (mediana, pior caso e melhor caso) para o pico de mortes pela doença (dia com mais mortes).

# Um Outro Resultado

Diego Marcondes



## Previsão para 22/09/2020

**Casos Confirmados: 285.952**  
**Melhor Cenário: 251.985**  
**Pior Cenário: 310.460**

**Mortes Confirmadas: 11.654**  
**Melhor Cenário: 10.868**  
**Pior Cenário: 12.607**

As previsões são realizadas através de Modelos SEIR Metapopulação com Mobilidade supondo que a evolução da doença se manterá da mesma forma que na semana terminando em 23/08/2020

**DISCLAIMER:** Apenas as previsões pontuais realizadas até o dia 22/09/2020 e a projeção do pico da doença devem ser considerados, para todos os DRSs e apenas para Municípios com mais de 500 casos ou 100 mortes em 23/08/2020 (os demais Municípios foram omitidos). Embora apresentadas nos gráficos, as previsões pontuais após 22/09/2020 **NÃO DEVEM SER CONSIDERADAS.**

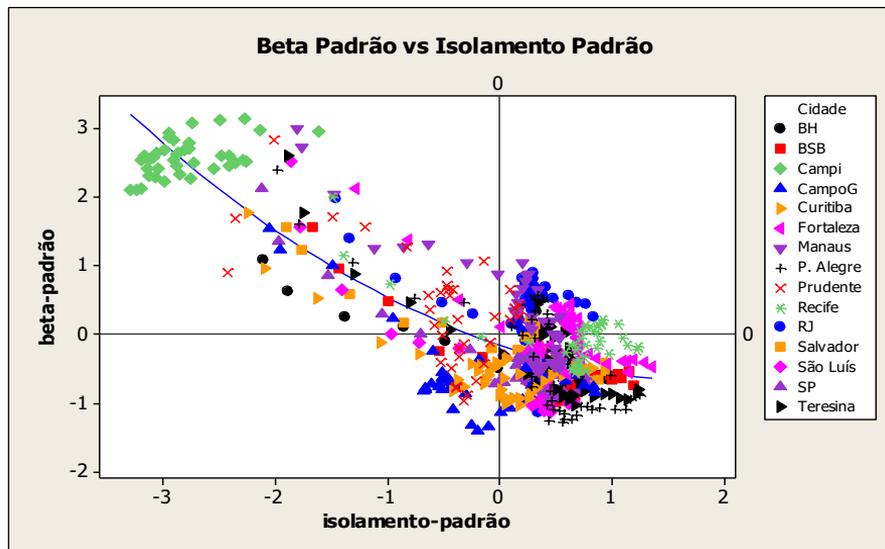
Desenvolvido por pesquisadores do **IME-USP**

Atualizado em 23/08/2020

\*Cada linha representa a previsão de um modelo. A linha grossa (mediana das previsões) e banda vermelha (melhor e pior caso) dizem respeito ao número de indivíduos que estão infectados simultaneamente na data. As linhas tracejadas são as estimativas (mediana, pior caso e melhor caso) para o pico de mortes pela doença (dia com mais mortes).

# Parcerias e novos estudos

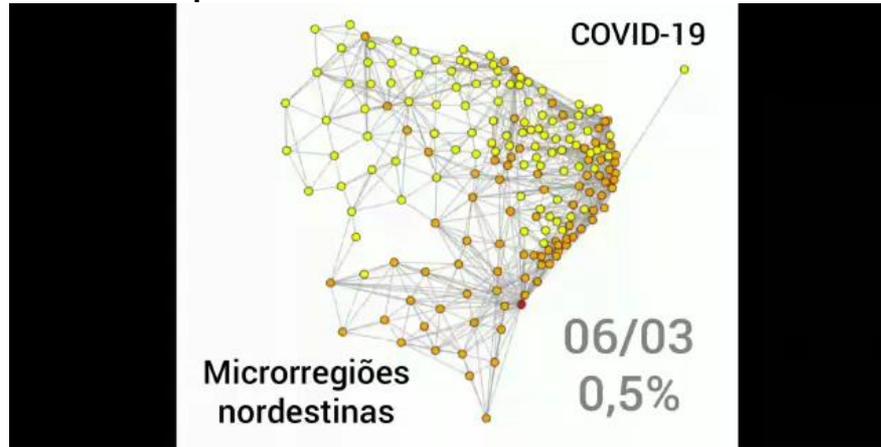
- modelo SEIR em redes para estimar  $R_t$  e relação com índice de isolamento



Claudia Pio e Claudia Peixoto

# Parcerias e novos estudos

- Modelo SEIR em redes, cálculo de índices para avaliação de risco (com Prof. Tiago Pereira – ICMC)
- Uso dos dados de mobilidade e testes de sorologia para avaliação do impacto em comunidades da Amazônia (com Prof. Marcelo Urbano – ICB)
- Melhoria dos dados e colaboração (Covid Radar, Governo do Estado e vários grupos).
- Consórcio Nordeste implementou mobilidade e índice de Katz para risco



# Parcerias e novos estudos

- CADDE centre, Brazil-UK  
Centre for Arbovirus Discovery, Diagnosis, Genomics and Epidemiology  
Modelagem de disseminação genômica  
<https://www.medrxiv.org/content/10.1101/2020.06.11.20128249v1>
- IAG-USP e ON-Brasil - Sísmica (Índice de Isolamento Sísmico).
- Miguel Nicolelis - Duke University  
Medidas de risco para Covid no nordeste
- CEMEI-USP e UNICAMP  
uso dos dados processados de mobilidade no projeto de quarentenas alternadas.

# Parcerias e novos estudos

- Observatório-COVID-BR  
Parceria de dados de saúde e análise de SRAG e Censo-covid  
Modelagem via nowcasting
- Projeto FAPESP-Covid19, em parceria com UNESP, UFABC.
- Michigan Center for Political Studies  
Métodos para processamento de dados geolocalizados
- UFV - Física - Modelagem com mobilidade espacial
- UEFS - COVID19 - Modelagem com mobilidade espacial
- Artigo “Large-scale assessment of human mobility during COVID-19 outbreak”, em parceria com FCF

OBRIGADO