

Vulnerabilidade das microrregiões do estado do Rio de Janeiro ao COVID-19 (SARS-CoV-2)

Kate P. Maia¹
Marília Palumbo Gaiarsa²
Pamela Santana³
Danilo G. Muniz⁴
Leandro Giacobelli⁵
Ana P. A. Assis⁶
Erika Marques Santana⁷
Irina Birskis-Barros⁸
Lucas P. Medeiros⁹
Flavia M. D. Marquitti¹⁰
Wesley Dáttilo¹¹
Mauricio Cantor¹²
Paula Lemos-Costa¹³
Rafael L. G. Raimundo¹⁴
Cecília S. Andreazzi¹⁵
Mathias M. Pires¹⁶
Paulo R. Guimarães Jr¹⁷
Eduardo X. F. G. Migon¹⁸

1. Sumário de resultados e recomendações

Este é o primeiro relatório do *Observatório COVID19¹⁹ - Grupo: Redes de Contágio – Laboratório de Estudos de Defesa* para o Estado do Rio de Janeiro.

¹ Instituto de Biociências, Universidade de São Paulo.

² Department of Entomology, University of California, Riverside, EUA.

³ Instituto de Biociências, Universidade de São Paulo.

⁴ Instituto de Biociências, Universidade de São Paulo.

⁵ Instituto de Biociências, Universidade de São Paulo.

⁶ Instituto de Biociências, Universidade de São Paulo.

⁷ Instituto de Biociências, Universidade de São Paulo.

⁸ School of Natural Sciences, University of California, Merced, EUA

⁹ Department of Civil and Environmental Engineering, MIT, EUA.

¹⁰ Instituto de Física "Gleb Wataghin", Universidade Estadual de Campinas.

¹¹ Instituto de Ecología AC, México.

¹² Departamento de Ecologia e Zoologia, Universidade Federal de Santa Catarina e Max Planck Institute of Animal Behaviour, Alemanha.

¹³ Department of Ecology and Evolution, University of Chicago, EUA.

¹⁴ Departamento de Engenharia e Meio Ambiente, Centro de Ciências Aplicadas e Educação (CCA), Universidade Federal da Paraíba. Autor para correspondência:

¹⁵ Instituto Oswaldo Cruz - RJ

¹⁶ Instituto de Biologia, Universidade Estadual de Campinas

¹⁷ Instituto de Biociências, Universidade de São Paulo. Autor para correspondência: prguima@usp.br

¹⁸ Laboratório de Estudos de Defesa, Escola de Comando e Estado-Maior do Exército. Autor para correspondência: eduardomigon@gmail.com

Combinamos dados de casos confirmados do novo coronavírus (SARS-CoV-2) para o Estado do Rio de Janeiro, até o dia 29/03, com análises estruturais da rede de rotas rodoviárias no estado para estimar a vulnerabilidade e a potencial influência de diferentes microrregiões do Estado na propagação da doença.

1.1. Principais resultados até o momento:

- I. A rede rodoviária do Rio de Janeiro é formada por 5 módulos rodoviários, isto é, conjuntos de microrregiões que estão mais conectadas entre si pelo fluxo rodoviário do que com outras microrregiões (**Figura 1 e 2**).
- II. A análise do fluxo rodoviário entre microrregiões, levando em consideração o fluxo dentro e entre módulos revela um total de seis microrregiões com potencial importância para a propagação da COVID-19. **Rio de Janeiro** serve de *hub regional* por possuir alta conectividade de fluxo rodoviário em todo o Estado. As microrregiões de **Barra do Piraí, Cantagalo-Cordeiro, Nova Friburgo, Santo Antônio de Pádua, Lagos** servem de *hubs locais* devido à alta conectividade entre cidades dentro dos mesmos módulos rodoviários (**Figura 3**).
- III. As microrregiões mais vulneráveis à epidemia são **Rio de Janeiro, Macaé e Campos dos Goytacazes** ou por já apresentarem diversos casos (**Tabela 1**), ou por ainda não apresentarem casos, mas estarem bastante conectadas (**Figura 4**).
- IV. As microrregiões com maior potencial de emissão de pacientes infectados são **Rio de Janeiro e o Vale do Paraíba Fluminense**.

2. Detalhamento das análises e resultados

Nós integramos dados rodoviários, ciência de redes complexas e noções de modelos epidemiológicos para prever áreas com maior risco à chegada de pessoas com COVID-19 e áreas com maior chance de enviarem pessoas contaminadas a outros locais. A partir dos dados do transporte rodoviário intermunicipal do Estado do Rio de Janeiro (IBGE, 2016), criamos uma rede na qual cada microrregião é representada por um ponto, e as viagens de ônibus ligando diferentes microrregiões são representados por linhas (**Figura 1**). As linhas são ponderadas pela quantidade de viagens realizadas entre os municípios. Para este relatório nós incorporamos uma análise de cartografia de redes complexas que detecta módulos nas redes rodoviária (Newman 2006, Brandes *et al.* 2008). Ressaltamos que esses *módulos rodoviários* (**Figura 1**) não são mesorregiões administrativas, mas sim grupos formados por microrregiões conectadas por intenso fluxo rodoviário (**Figura 2**). Dessa maneira, um

¹⁹ <https://covid19br.github.io/>

módulo rodoviário é um grupo de microrregiões que tem maior fluxo rodoviário entre si em comparação ao fluxo com microrregiões fora do módulo.

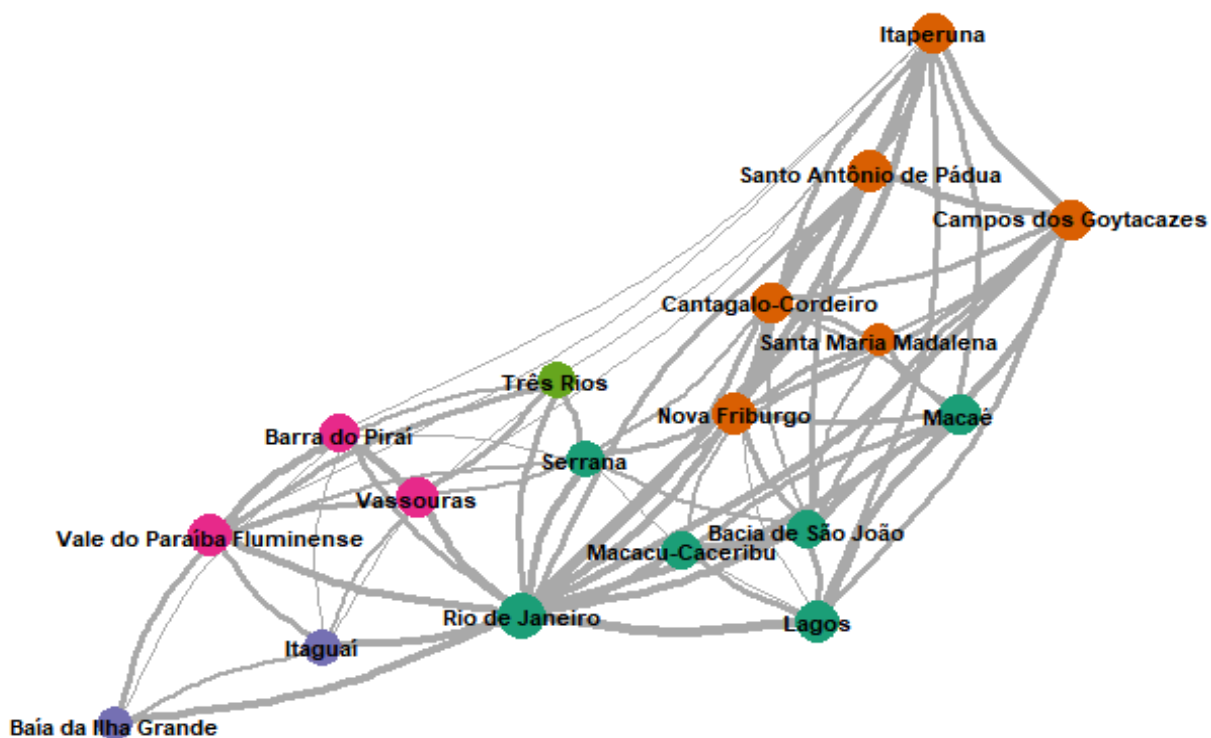


Figura 1. Rede que descreve o fluxo rodoviário entre as microrregiões no Rio de Janeiro. Microrregiões com as mesmas cores formam módulos rodoviários, isto é, microrregiões altamente conectadas entre si e que tem potencial de responder de forma sincrônica à epidemia.

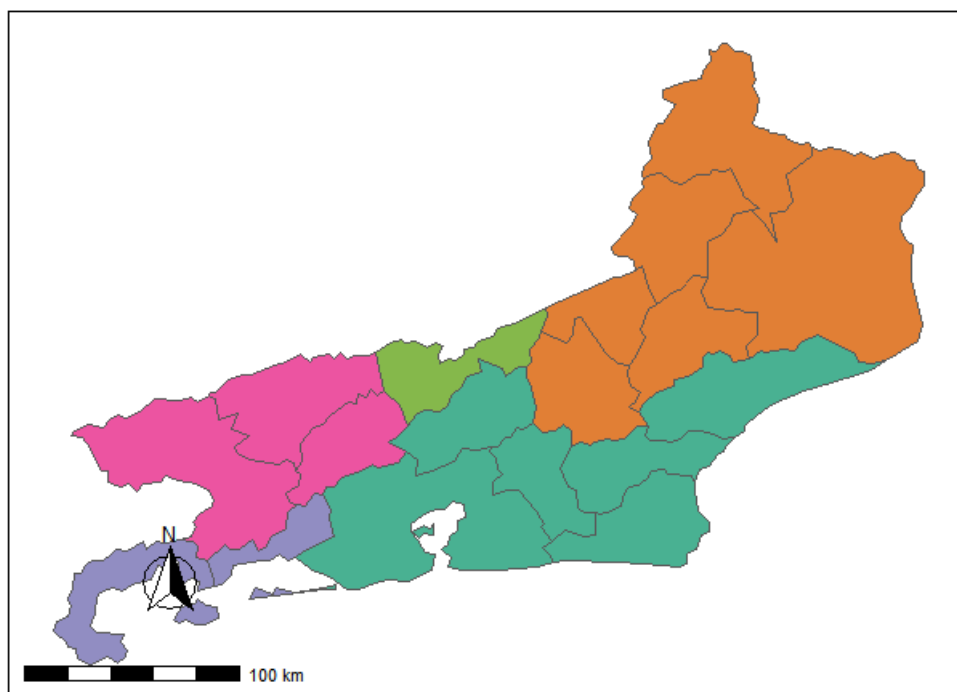


Figura 2. *Projeção geográfica dos módulos rodoviários no mapa do Rio de Janeiro. As cores correspondem aos módulos detectados e representam microrregiões altamente conectadas entre si na rede de fluxo rodoviário (Figura 1).*

Nós então computamos descritores que caracterizam a conectividade das microrregiões e que levam em conta os 5 módulos rodoviários identificados. Nesse contexto, conectividade representa o número total de viagens no qual a microrregião está envolvida. A partir dessa métrica, computamos descritores relacionados ao papel topológico desempenhado por cada microrregião e que capturam o quanto dessa conectividade envolve viagens que ocorrem dentro do módulo ao qual pertence cada microrregião (*conectividade intramodulo*) e viagens que ocorrem com microrregiões pertencentes a diferentes módulos rodoviários (*conectividade intermodulo*) (Amaral et al. 2000, **Figura 3**).

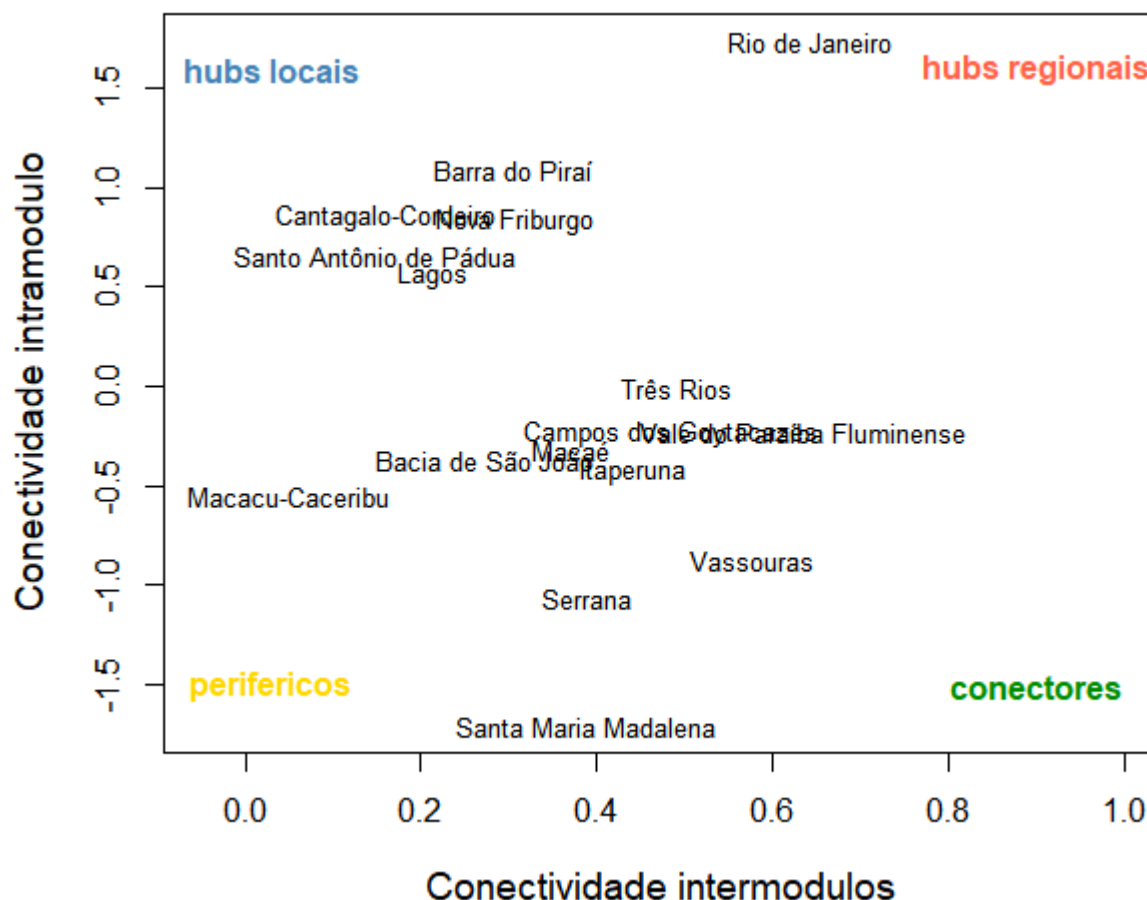


Figura 3. Descritores quantitativos da conectividade intermódulo (entre os módulos rodoviários) e da conectividade intramódulo (dentro dos módulos).

Ressaltamos que os módulos rodoviários são grupos formados por microrregiões conectadas por intenso fluxo rodoviário (Figura 2). Valores altos de conectividade intramódulo indicam microrregiões com grande tráfego rodoviário com outras microrregiões pertencentes ao mesmo módulo da microrregião focal. Valores altos de conectividade intermódulos indicam microrregiões com grande tráfego rodoviário entre microrregiões pertencentes a outros módulos rodoviários. Núcleos (hubs regionais e locais) e conectores são as microrregiões que apresentam papel topológico central na rede de fluxo rodoviário e que por consequência conectam diferentes grupos de microrregiões. As diferentes microrregiões variam marcadamente na sua conectividade intramódulo. Porém, **Rio de Janeiro** se destaca como um *hub regional* (Figura 3), por apresentar valores altos de conectividade intra e intermódulos, enquanto **Barra do Piraí**, **Cantagalo-Cordeiro**, **Nova Friburgo**, **Santo Antônio de Pádua** e **Lagos** se destacam como *hubs locais*, por apresentarem valores altos de conectividade intramódulos (Figura 3).

As análises descritas acima caracterizam a posição relativa das microrregiões na estrutura da rede, mas podem não capturar adequadamente seus efeitos na propagação geográfica da epidemia, particularmente considerando-se o grande número de rotas indiretas que compõem uma rede geográfica com a dimensão do Nordeste brasileiro. De forma complementar, portanto, usamos uma técnica que descreve a propagação de efeitos em redes complexas considerando a posição das microrregiões no conjunto de rotas diretas e indiretas que compõem a rede geográfica. Combinamos a rede de transporte rodoviário fluminense, com dados atualizados (até o dia 29/03/2020) de casos confirmados de COVID-19 nos diferentes municípios do Estado do Rio de Janeiro. Especificamente, adaptamos uma medida que permite computar rotas diretas e indiretas entre microrregiões (centralidade de Katz). Para calcular essa medida nós computamos a matriz de efeitos diretos e indiretos (Katz, 1956; Guimarães et al., 2017): $T = (I - rQ)^{-1}$, no qual I é a matriz identidade, r é um fator que pesa o efeito de rotas rodoviárias que envolvam múltiplas microrregiões e Q descreve a matriz de fluxo rodoviário entre microrregiões.

Nossa abordagem supõe, como aproximação, que se uma microrregião apresenta casos, ela pode propagar a doença para uma região que dela receba passageiros pelo sistema rodoviário. Para isso, utilizamos os dados de circulação de ônibus entre as microrregiões do estado (IBGE, link abaixo) para calcular a matriz de efeitos diretos e indiretos como descrito acima. Porém, nós apenas consideramos as rotas rodoviárias diretas e indiretas que partem de áreas com casos comprovados de COVID-19 (até o dia 29/03/2020). Calculamos então a centralidade Katz de todas as microrregiões como uma medida de vulnerabilidade daquela região, de forma que quanto maior a centralidade, maior o fluxo de passageiros vindos de microrregiões onde a COVID-19 foi confirmada. Como o fluxo de passageiros pode depender também do tamanho populacional de cada microrregião, ponderamos essa medida pelos seus respectivos tamanhos populacionais (em escala logarítmica). Então, dividimos cada valor pelo valor máximo observado para que a medida ficasse entre zero e um, facilitando sua interpretação. Para obter uma medida da potencial influência de cada microrregião como emissora da COVID-19, anotamos as microrregiões mais vulneráveis e que já possuem casos confirmados. Quanto maior esse valor, maior o fluxo de passageiros que saem da região onde a COVID-19 foi observada para outras microrregiões por meio de rotas diretas e indiretas. Nessa análise, microrregiões onde a COVID-19 não foi observada têm potencial de emissão zero na propagação da COVID-19. Novamente, dividimos os valores pelo máximo observado para que a medida ficasse entre zero e um.

Abaixo apresentamos um mapa com as microrregiões divididas em três grupos de risco. Representações espaciais dos índices de vulnerabilidade podem ser obtidas na **Figura 4**. Ressaltamos que esses grupos estão definidos de forma heurística e tem

como objetivo facilitar a tomada de decisões. As regiões mais vulneráveis são **Rio de Janeiro**, por apresentar o maior número de casos e alta conectividade intra e intermódulos rodoviários, seguida de **Lagos** que apresenta alta conectividade intramódulo, mas ainda nenhum caso registrado (**Tabela 1; Figura 4**). Outras microrregiões vulneráveis incluem **Macaé** e **Campos dos Goytacazes** por ainda não apresentarem casos detectados, mas apresentarem índice de vulnerabilidade alta (**Tabela 1; Figura 4**). Entre as regiões que podem ser importantes emissoras de pessoas infectadas, além da **capital**, merecem especial atenção o **Vale do Paraíba Fluminense** (**Figura 4**).




Figura 4. Mapa com as microrregiões do Estado do Rio de Janeiro. As cores indicam a categoria de vulnerabilidade da microrregião à chegada de pessoas com COVID-19 (com base no número de casos reportados em 29/03/2020). Quanto maior a vulnerabilidade, maior o potencial daquela microrregião de receber pessoas com COVID-19. Para regiões já infectadas, quanto maior o índice, maior também o potencial daquela microrregião em servir como ponto de propagação (emissão) de infectados para outras microrregiões.

Tabela 1. Índice de vulnerabilidade à propagação da COVID-19 das microrregiões do Estado do Rio de Janeiro. Quanto maior o valor, maior o potencial daquela microrregião de receber pessoas com COVID-19 (valor baseado no número de casos reportados para o Estado em 29/03/2020). Para regiões já infectadas, quanto maior o índice, maior também o potencial daquela microrregião em servir como ponto de propagação (emissão) de infectados para outras microrregiões.

Microrregião	Casos	Índice de vulnerabilidade	Categoria
Rio de Janeiro	576	1	alta
Lagos	0	0.5881	alta
Vale do Paraíba Fluminense	13	0.3932	alta
Macaé	0	0.3633	alta
Campos dos Goytacazes	1	0.3331	alta
Nova Friburgo	0	0.2746	intermediária
Vassouras	1	0.2742	intermediária
Santo Antônio de Pádua	0	0.2578	intermediária
Itaperuna	0	0.2483	intermediária
Bacia de São João	0	0.2458	intermediária
Macacu-Caceribu	0	0.2172	intermediária
Cantagalo-Cordeiro	0	0.2029	intermediária
Serrana	4	0.1717	intermediária
Barra do Pirai	1	0.1662	intermediária
Itaguaí	2	0.1098	intermediária
Baía da Ilha Grande	2	0.0855	baixa
Três Rios	0	0.0517	baixa
Santa Maria Madalena	0	0.032	baixa

3. Limitações

Ressaltamos aqui uma série de limitações em nossas análises. Para sanar algumas delas, estamos trabalhando continuamente com colaboradores. Em outros

casos, ressaltamos a importância de dados que no momento não estão disponíveis para que possamos melhorar nossas inferências e, assim, ajudar de forma mais eficiente na tomada de decisões. Por fim, há limitações que são intrínsecas de qualquer análise e que aqui evidenciamos.

Dados sobre a infecção: **Uma grande limitação que atualmente enfrentamos é a ausência de dados disponibilizados rapidamente, por município, de infecção por COVID-19.** Nossa ideia é usar ferramentas de *machine learning* – algoritmos computacionais que fazem uso de dados anteriores para gerar previsões uma vez que novos dados são obtidos – para, diariamente, verificar e refinar as previsões em tempo hábil de prover informações técnicas. Porém, sem os dados sobre os infectados por COVID-19 que estão hospitalizados por município, tal abordagem é inviável. Ainda, há outras fontes de erro nos dados associadas a subnotificações, atraso no aparecimento dos sintomas e ausência de testes diagnósticos de um grande número de pessoas.

Dinâmica entre e dentro de microrregiões: epidemias possuem duas dinâmicas de propagação bem distintas apesar de relacionadas, que são a propagação dentro de uma localidade e a propagação entre localidades. Nossa análise se refere apenas à propagação da COVID-19 entre localidades (neste caso, microrregiões do Estado do Rio de Janeiro) e não dentro de uma localidade (neste caso, dentro de cada cidade). Dentro de uma cidade a rede de contatos entre pessoas é determinante para a propagação da doença. Entre regiões, a propagação da doença depende da rede de contatos e também da rede de conexões ligando diferentes microrregiões. Nesse sentido, nossa análise apenas avalia o componente rodoviário do problema. Por isso nossa análise pode apenas ser usada para ajudar a identificar locais que poderão ser mais rapidamente atingidos pela epidemia, mas não permite identificar o quão grande será o número de infectados em cada microrregião. Estamos tentando obter estimativas e incorporando a distância efetiva entre microrregiões, usando como base um modelo epidemiológico desenvolvido pelo Núcleo de Métodos Analíticos para Vigilância em Saúde Pública do PROCC/Fiocruz, EMap/FGV e colaboradores. Com esses novos dados, poderemos incorporar o efeito da dinâmica dentro das microrregiões nas previsões entre microrregiões. Neste sentido, é importante notar que modelos epidemiológicos sugerem que o crescimento de uma epidemia dentro de uma microrregião tem um efeito marcante sobre a propagação da doença entre microrregiões (veja por exemplo o relatório da FIOCRUZ sobre o COVID-19).

Dados do fluxo rodoviário: Nós usamos os dados do transporte rodoviário intermunicipal no Estado do Rio de Janeiro obtidos pelo IBGE (IBGE, 2016 - <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/redes-e-fluxos-geograficos/15794-rodoviaras-e-hidroviarias.html?=&t=o-que-e>). Esses dados são fruto de uma pesquisa feita com o uso de questionários deixados nos guichês dos terminais

rodoviários e em pontos lado de fora dos terminais. Desta forma, representa uma amostragem do fluxo rodoviário e nossos resultados podem ser dependentes e influenciados pelos problemas associados a qualquer amostragem. Devido à esta forma de amostragem, sabemos que algumas rotas estão subamostradas. Para sanar este possível viés pretendemos de estimar o fluxo entre locais de outras formas, como por exemplo usando um modelo gravitacional ponderado pelos tamanhos populacionais de cada microrregião. **Porém qualquer outra estimativa de fluxo rodoviário (ônibus, carros, veículos por pedágios, por exemplo) poderia nos ajudar a validar a robustez de nossas previsões.** Ainda, é importante notar que não estamos considerando o fluxo de pessoas de outros estados e países, o que provavelmente subestima o papel das microrregiões relacionadas às fronteiras do Estado.

Apesar de todas as fontes de erro listadas acima, ao usar uma abordagem similar para prever a propagação da COVID-19 entre estados por meio da rede aérea, a nossa abordagem explicou > 56% da variação das datas do primeiro registro de COVID-19 por entre os estados brasileiros (por favor, veja em <https://guimaraeslabbr.weebly.com/voos.html>).

4. Agradecimentos

Nossos especiais agradecimentos a Marcelo Gomes (Fiocruz), Roberto Kraenkel (IFT-UNESP) e Paulo I. Prado (IB-USP). À FAPESP, CAPES e CNPq por financiarem nossos grupos de pesquisa.

5. Referências

Amaral, L. A. N., Scala, A., Barthelemy, M., & Stanley, H. E. (2000). Classes of small-world networks. *Proceedings of the national academy of sciences*, 97(21), 11149-11152.

Brandes, U.; Dellinger, D.; Gaertler, M.; Gorke, R.; Hofer, M.; Nikoloski, Z.; Wagner, D. (2008). On Modularity Clustering. *IEEE Transactions on Knowledge and Data Engineering*. 20 (2): 172–188.

Guimarães, P. R.; Pires, M. M.; Jordano, P; Bascompte, J; Thompson, J. N. (2017). Indirect effects drive coevolution in mutualistic networks. *Nature*, 550: 511-514.

IBGE Instituto Brasileiro de Geografia e Estatística. Censo Demográfico 2010: Resultados gerais da amostra [Internet]. (2010). Disponível em: http://www.ibge.gov.br/home/estatistica/populacao/censo2010/resultados_gerais_amostra/resultados_gerais_amostra_tab_uf_microdados.shtm

IBGE Instituto Brasileiro de Geografia e Estatística. Ligações Rodoviárias e Hidrovias. (2016). Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/redes-e-fluxos-geograficos/15794-rodoviaras-e-hidroviarias.html?=&t=o-que-e>

Katz, L. (1953). A new status index derived from sociometric analysis. *Psychometrika*, 18(1), 39-43.

Newman, M. E. J. (2006). Modularity and community structure in networks. *Proceedings of the National Academy of Sciences of the United States of America*. 103 (23): 8577–8696.