

Vulnerabilidade das microrregiões do Estado de São Paulo à pandemia do novo coronavírus (SARS-CoV-2)

Relatório 6 - 05/04/2020 - 11:30 PM

Observatório COVID19 - Grupo: Redes de Contágio^a & Eduardo X. F. G. Migon^b

^a - *Participantes do COVID-19BR* -(<https://covid19br.github.io/>): Grupo Redes de Contágio: Danilo G. Muniz¹, Leandro Giacobelli¹, Kate P. Maia¹, Marília Palumbo Gaiarsa², Ana Paula A. Assis¹, Pamela Santana¹, Erika Marques Santana¹, Irina Birskis-Barros³, Lucas P. Medeiros⁴, Viviana Márquez Velásquez⁹, Gustavo Burin¹, Flavia M. D. Marquitti⁵, Marina C. Côrtes¹², Wesley Dáttilo⁶, Mauricio Cantor⁷, Paula Lemos-Costa⁸, Rafael L. G. Raimundo¹³, Cecília Andreazzi¹⁰, Mathias M. Pires¹¹, Paulo R. Guimarães Jr.¹

^b - Laboratório de Estudos de Defesa, Escola de Comando e Estado-Maior do Exército (LED/ECEME)

¹ - Instituto de Biociências, Universidade de São Paulo;

² - Department of Entomology, University of California, Riverside, EUA;

³ - School of Natural Sciences, University of California, Merced, EUA;

⁴ - Department of Civil and Environmental Engineering, MIT, EUA;

⁵ - Instituto de Física "Gleb Wataghin", Universidade Estadual de Campinas;

⁶ - Instituto de Ecología AC, México;

⁷ - Departamento de Ecologia e Zoologia, Universidade Federal de Santa Catarina; Department for the Ecology of Animal Societies, Max Planck Institute of Animal Behaviour, Alemanha;

⁸ - Department of Ecology & Evolution, University of Chicago, EUA;

⁹ - Programa de Pós-Graduação em Ciências Biológicas, Universidade Federal da Paraíba;

¹⁰ - Instituto Oswaldo Cruz - RJ;

¹¹ - Instituto de Biologia, Universidade Estadual de Campinas.

¹² - Instituto de Biociências, Universidade Estadual Paulista, Rio Claro.

¹³ - Departamento de Engenharia e Meio Ambiente, Centro de Ciências Aplicadas e Educação, Universidade Federal da Paraíba;

1. Adições deste relatório e principais resultados até o momento

Neste relatório, associamos dados da rede de fluxos rodoviários e da demografia das microrregiões paulistas com os casos confirmados de COVID-19 atualizados em 04/04/2020 para gerar informações estratégicas sobre a propagação geográfica da pandemia de SARS-CoV-2 no Estado de São Paulo. Identificamos microrregiões que podem atuar como núcleos propagadores da epidemia ou que têm alta vulnerabilidade a receber pessoas infectadas. Desta forma, atualizamos a identificação das microrregiões mais vulneráveis à propagação geográfica da pandemia do novo coronavírus (SARS-CoV-2) no estado, conforme demonstrado na **Figura 3**. A seguir, descrevemos o cenário atualizado.

Principais resultados

1. Identificamos cinco microrregiões ainda sem casos confirmados de COVID-19 que têm *alta vulnerabilidade* à chegada de pessoas infectadas com o SARS-CoV-2 via rede rodoviária, a seguir listadas em ordem decrescente de vulnerabilidade: **Jaboticabal, Bragança Paulista, Presidente Prudente, Marília e Adamantina**
2. Identificamos cinco microrregiões que constituem potenciais *núcleos propagadores* em escala geográfica porque já têm casos confirmados de COVID-19 e que, consideradas suas posições na rede rodoviária estadual, são mais propensas a emitirem pessoas infectadas pela COVID-19 para outras microrregiões. Esses potenciais núcleos propagadores são listados a seguir, em ordem decrescente de influência na rede rodoviária: **São Paulo, Campinas, Santos, Sorocaba e São José do Rio Preto**.

2. Detalhamento das análises e resultados

Nós integramos dados rodoviários, análises estruturais de redes e princípios de epidemiologia para prever (i) áreas mais suscetíveis à chegada de pessoas com COVID-19 e (ii) áreas com maior chance de enviar pessoas contaminadas a outros locais. A partir dos dados do transporte rodoviário intermunicipal do Estado de São Paulo (IBGE, 2016), criamos uma rede (grafo) na qual cada microrregião é representada por um ponto e as rotas de ônibus ligando diferentes micro-regiões são representados por linhas. As linhas são ponderadas pela quantidade de viagens realizadas em cada rota intermunicipal e também são direcionadas, isto é, são considerados separadamente os números de ônibus que chegam e saem da microrregião. Incorporamos uma análise de redes complexas que detecta módulos nas redes rodoviárias (Newman 2006, Brandes *et al.* 2008.). Ressaltamos que tais *módulos rodoviários* não são mesorregiões administrativas, mas sim grupos formados por

microrregiões mais conectadas entre si por intenso fluxo rodoviário do que com as demais microrregiões do Estado (**Figura 1**).

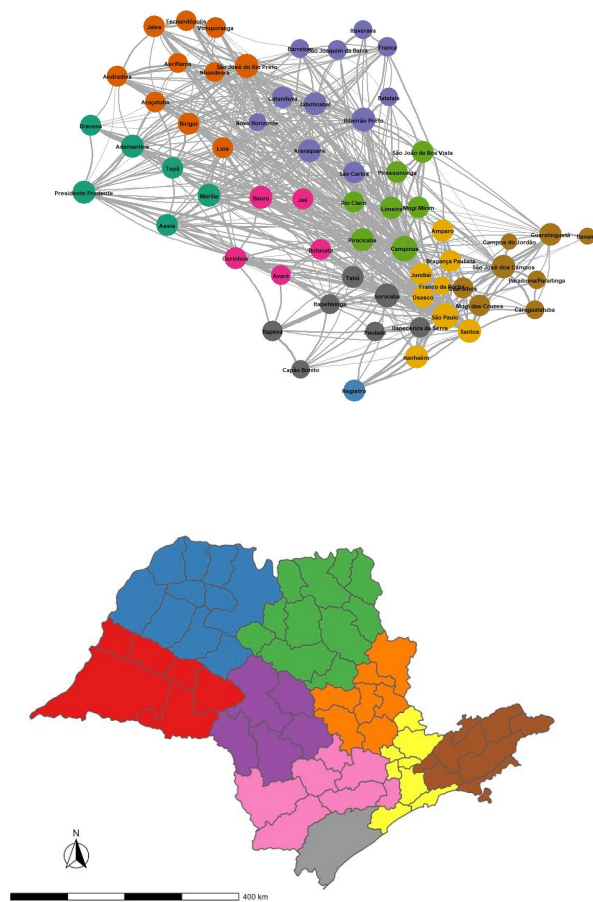


Figura 1. *Acima, a rede que descreve o fluxo rodoviário entre as microrregiões do Estado de São Paulo. Microrregiões com as mesmas cores pertencem ao mesmo módulo rodoviário, isto é, são altamente interconectadas por fluxos de pessoas e, portanto, podem apresentar dinâmica epidemiológica relativamente sincrônica. Abaixo, o mapa mostra as microrregiões que compõem cada um dos nove módulos rodoviários.*

Computamos descritores que caracterizam a conectividade das microrregiões — o número total de viagens relacionadas a uma microrregião — e que levam em conta os nove módulos rodoviários identificados. Usamos descritores que identificam o quanto dessa conectividade envolve viagens dentro de módulos rodoviários e viagens entre módulos rodoviários (Amaral *et al.* 2000). De forma heurística, podemos identificar dois grupos de microrregiões que com potencial relevância central na dinâmica epidemiológica em escala geográfica (**Figura 2**).

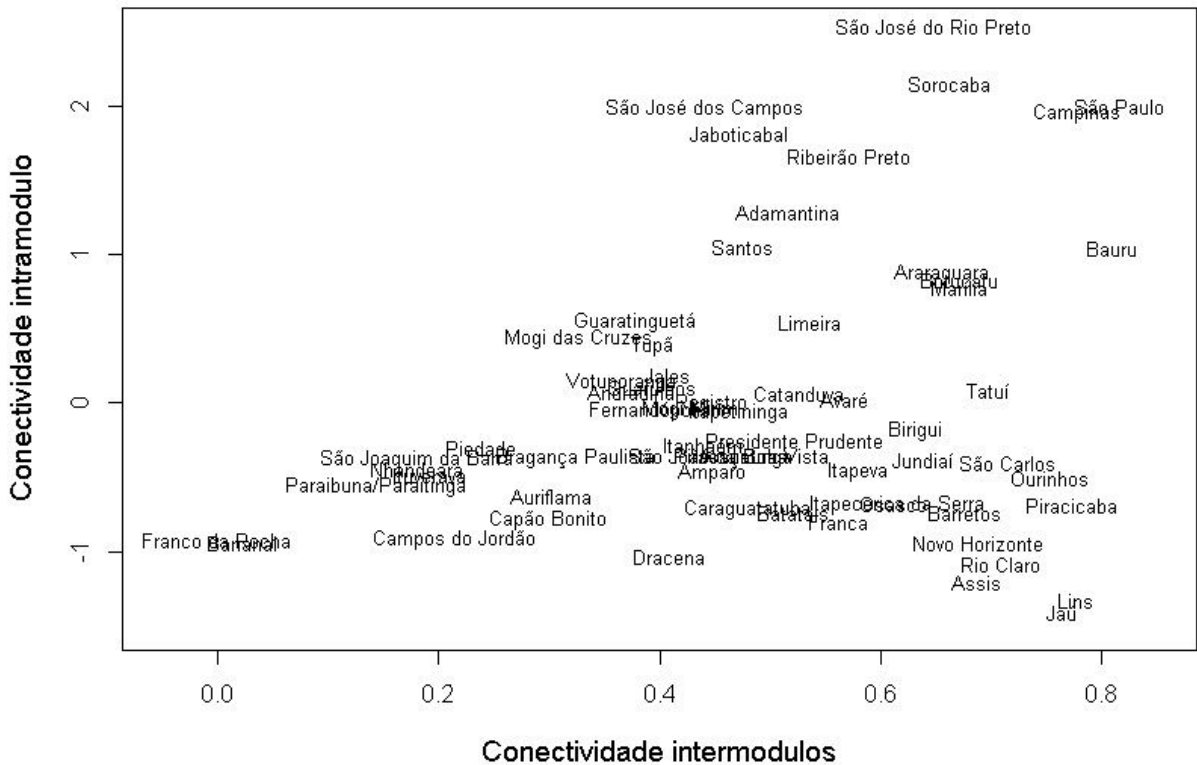


Figura 2. Descritores quantitativos da conectividade *intermodular* (viagens entre os módulos rodoviários) e conectividade *intramodular* (dentro dos módulos). Módulos rodoviários são grupos formados por microrregiões mais interconectadas entre si por intenso fluxo rodoviário do que com as demais microrregiões do Estado. Valores altos de conectividade intramodular indicam microrregiões com grande tráfego rodoviário com outras microrregiões próximas. Valores altos de conectividade intermodular indicam microrregiões com grande tráfego rodoviário entre módulos rodoviários distintos.

O primeiro grupo é formado por cinco microrregiões que podem ser caracterizadas como *hubs* geográficos — isto é, apresentam alta conectividades intra e intermodular — e, por consequência, são muito vulneráveis ao espalhamento da COVID-19 e provavelmente constituem corredores centrais de propagação da epidemia: **São José do Rio Preto, São Paulo, Campinas, São José dos Campos e Sorocaba (Figura 2 — canto superior direito)**. O segundo grupo inclui cinco microrregiões que, assim como as microrregiões do primeiro grupo, atuam como conectores da rede geográfica ao ligar grupos de microrregiões de distintos módulos rodoviários (e, portanto, podem ser importantes para propagar a epidemia no Estado),

mesmo não sendo locais particularmente populosos ou conectadas localmente: **Bauru, Lins, Jaú, Piracicaba e Ourinhos (Figura 2 — canto inferior direito).**

Nós também analisamos o **potencial de auto-contágio** de uma microrregião. O potencial de auto-contágio descreve o fluxo rodoviário dentro de uma microrregião comparativamente com o fluxo rodoviário de saída e chegada da mesma microrregião. Desta forma, é uma medida da intensidade relativa do fluxo entre municípios da própria microrregião. 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 pondera o efeito de rotas rodoviárias que envolvam múltiplas microrregiões e Q descreve a matriz de fluxo rodoviário entre microrregiões. O elemento t_{ii} descreve o fluxo rodoviário dentro da microrregião e viagens de ida-e-volta envolvendo a microrregião. Nós padronizamos este índice pelo número de rotas envolvendo a microrregião e identificamos 10 microrregiões que apresentam um fluxo interno relativamente alto, nesta ordem: **Campinas, Ribeirão Preto, Presidente Prudente, São José do Rio Preto, São Paulo, Jaboticabal, Piracicaba, Sorocaba, Santos e Mogi Mirim.**

Estas análises representam uma tentativa de descrever a vulnerabilidade estrutural da rede rodoviária paulista a epidemias. Combinamos a rede de transporte rodoviário paulista com dados atualizados (até dia 04/04/2020) de casos confirmados de COVID-19 nos diferentes municípios paulistas (<https://labs.wesleycota.com/sarscov2/br/#cidadesTempo> e <http://saude.sp.gov.br/ses/perfil/cidadao/homepage/destaques/sp-registra-48-obito-s-relacionados-a-covid-19>). **Os resultados abaixo são atualizações do relatório anterior. Ressaltamos a importância de obtermos os dados diários, por município, de casos da COVID-19 para validação e melhoria dessas previsões.**

Nós usamos técnicas associadas à descrição de como efeitos se propagam em redes complexas. Especificamente, para o problema em questão nós adaptamos uma medida que permite computar rotas diretas e indiretas entre microrregiões (centralidade de Katz, [Katz, 1956]). 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 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 04/04/2020**). Adicionalmente, para incluir o efeito no número de infectados nessa análise, multiplicamos a força de interação das ligações saindo de cada microrregião infectada pelo logaritmo natural do número de infectados confirmados. 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 variasse entre zero e um, facilitando sua interpretação. Uma das consequências das mudanças que implementamos desde o último relatório é que agora temos apenas um índice relacionado à centralidade Katz — neste relatório, chamaremos esse índice de *vulnerabilidade*. Para microrregiões onde já foi observado o COVID-19, esta métrica representa tanto a vulnerabilidade ao recebimento de novos infectados, quanto o potencial daquela microrregião de emitir infectados para outras microrregiões. Para microrregiões ainda sem casos de COVID-19, a métrica representa a vulnerabilidade ao recebimento de infectados. Usamos esse índice para classificar as microrregiões em três grupos (categorizando as microrregiões de acordo com o valor do índice em escala logarítmica): alto risco, risco intermediário e baixo risco. Com isso, identificamos as cinco microrregiões com maior potencial de *emitir infectados*: **São Paulo, Campinas, Santos, Sorocaba e São José do Rio Preto**. Identificamos também as cinco microrregiões com maior potencial de *receber infectados* neste momento: **Jaboticabal, Bragança Paulista, Presidente Prudente, Marília e Adamantina**.

Na **Figura 3** apresentamos um mapa com as microrregiões divididas em grupos de risco de emitir (se já possuem registros de contágio) ou receber (se ainda não possuem registros de contágio) pessoas com COVID-19, bem como representações espaciais dos índices de vulnerabilidade. Disponibilizamos também as tabelas com a classificação de cada microrregião quanto a sua vulnerabilidade à COVID-19 (**Tabela 1**). Ressaltamos que esses grupos estão definidos de forma heurística, e a divisão tem com objetivo facilitar a tomada de decisões. A COVID-19 já foi observada em **Santos e Itanhaém**, colocando em risco microrregiões socialmente vulneráveis como **Registro e Capão Bonito**. No interior, a região de **Sorocaba** passou de criticamente vulnerável para uma microrregião com alto potencial de emissão de infectados.

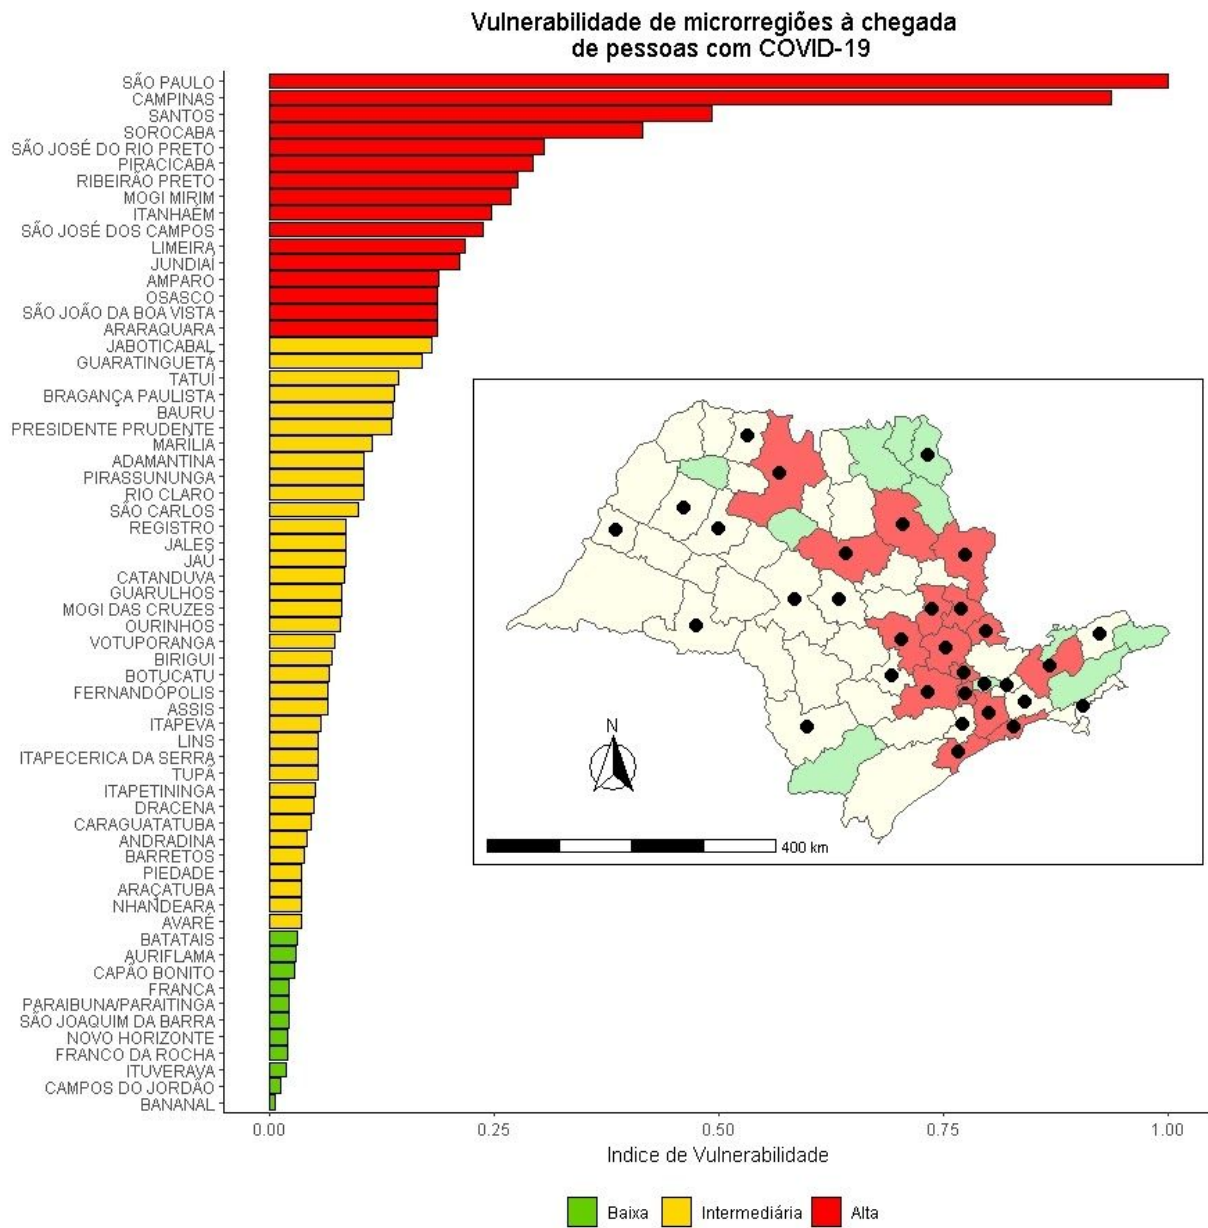


Figura 3. Mapa com as microrregiões do Estado de São Paulo. Os pontos no mapa indicam microrregiões que apresentam casos confirmados. As cores indicam a vulnerabilidade da microrregião à chegada e/ou emissão de pessoas com COVID-19. Os dados utilizados são referentes à 04/04/2020.

Tabela 1. Índice de vulnerabilidade à propagação da COVID-19 das microrregiões do Estado de São Paulo. Quanto maior o valor, maior o potencial daquela microrregião de receber pessoas com COVID-19 em 04/04/2020. 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	Índice de vulnerabilidade	Categoria
São Paulo	1	alto
Campinas	0.9368	alto
Santos	0.4933	alto
Sorocaba	0.4156	alto
São José Do Rio Preto	0.3054	alto
Piracicaba	0.293	alto
Ribeirão Preto	0.2764	alto
Mogi Mirim	0.269	alto
Itanhaém	0.2475	alto
São José Dos Campos	0.2378	alto
Limeira	0.2183	alto
Jundiaí	0.2126	alto
Amparo	0.1883	alto
Osasco	0.1876	alto
São João Da Boa Vista	0.1876	alto
Araraquara	0.1865	alto
Jaboticabal	0.181	intermediário

Guaratinguetá	0.1702	intermediário
Tatuí	0.1444	intermediário
Bragança Paulista	0.1394	intermediário
Bauru	0.1378	intermediário
Presidente Prudente	0.1367	intermediário
Marília	0.1142	intermediário
Adamantina	0.106	intermediário
Pirassununga	0.105	intermediário
Rio Claro	0.1049	intermediário
São Carlos	0.099	intermediário
Registro	0.0853	intermediário
Jales	0.0847	intermediário
Jaú	0.0847	intermediário
Catanduva	0.0832	intermediário
Guarulhos	0.0812	intermediário
Mogi Das Cruzes	0.0807	intermediário
Ourinhos	0.079	intermediário
Votuporanga	0.0731	intermediário
Birigui	0.0693	intermediário
Botucatu	0.0666	intermediário
Fernandópolis	0.0659	intermediário
Assis	0.0658	intermediário
Itapeva	0.0573	intermediário
Lins	0.0552	intermediário

Itapecerica Da Serra	0.0551	intermediário
Tupã	0.054	intermediário
Itapetininga	0.0515	intermediário
Dracena	0.0495	intermediário
Caraguatatuba	0.0463	intermediário
Andradina	0.0418	intermediário
Barretos	0.0389	intermediário
Piedade	0.0367	intermediário
Araçatuba	0.0363	intermediário
Nhandeara	0.036	intermediário
Avaré	0.0354	intermediário
Batatais	0.0321	baixo
Auriflama	0.0295	baixo
Capão Bonito	0.0275	baixo
Franca	0.0225	baixo
Paraibuna/Paraitinga	0.0219	baixo
São Joaquim Da Barra	0.0218	baixo
Novo Horizonte	0.0201	baixo
Franco Da Rocha	0.0198	baixo
Ituverava	0.0187	baixo
Campos Do Jordão	0.013	baixo
Bananal	0.0064	baixo

3. Limitações

Ressaltamos aqui as limitações de nossas análises. Para sanar algumas delas, estamos trabalhando continuamente com colaboradores. Ressaltamos a importância de dados que no momento não estão disponíveis para a melhoria das 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 doença: **Uma grande limitação que atualmente enfrentamos é a ausência de dados disponibilizados rapidamente, por município, da doença.** Nossa ideia é usar ferramentas de *machine learning* para, diariamente, verificar e refinar as previsões em tempo hábil de prover informações técnicas. Porém, sem os dados sobre os pacientes 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 — 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 de São Paulo) 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 e 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 têm 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 do Estado de São Paulo obtidos pelo IBGE (IBGE, 2016 - <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/redes-e-fluxos-geograficos/15794-rodovias-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 à qualquer amostragem. Devido à esta forma de amostragem, sabemos que algumas rotas estão sub-amostradas. Estamos tentando outras formas de estimar o fluxo entre locais, 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) poderiam nos ajudar a validar a robustez de nossas previsões.** Ainda, é importante notar que não consideramos o fluxo de pessoas de outros estados e países, o que provavelmente subestima o papel das microrregiões relacionadas às fronteiras do Estado. Por fim, espera-se que a suspensão nas linhas de ônibus em resposta à pandemia reduza a velocidade com que a pandemia se espalhará pelo Estado, porém é difícil estimar esse efeito quantitativamente.

Apesar de todas estas fontes de erro, 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) e a Roberto Kraenkel (IFT-UNESP). À FAPESP, CAPES e CNPq por financiarem nossos grupos de pesquisa.

5. Conflito de interesse

Não temos conflito de interesse.

6. Referências

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

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

Guimarães *et al.* (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_a_mostra/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.