

Declaração de Direito Autoral A Participação adota a Licença Creative Commons de Atribuição (CC-BY 4.0) em todos os trabalhos publicados, de tal forma que são permitidos não só o acesso e download gratuitos, como também o compartilhamento, desde que sem fins lucrativos e reconhecida a autoria. Fonte:

<https://periodicos.unb.br/index.php/participacao/about/submissions>.

Acesso em: 19 jul. 2021.

REFERÊNCIA

COLLI, Guarino Rinaldi *et al.* Modelo espaço-temporal bayesiano da difusão do SARS-CoV2 nos municípios brasileiros. **Participação**, Brasília, ano 19, ed. esp., n. 34, p. 147-149, nov. 2020. Disponível em:

https://drive.google.com/file/d/1_y95_7QMT_wC8vhwQUCJamcPgTvbjtBC/view.

Acesso em: 19 jul. 2021.

Modelo espaço-temporal bayesiano da difusão do SARS-CoV2 nos municípios brasileiros

Bayesian spatial-temporal model for the diffusion of SARS-CoV2 in Brazilian municipalities

Guarino Rinaldi Colli¹
Tarcísio Lyra dos Santos Abreu
Jéssica Fenker Antunes
Ísis da Costa Arantes
Renan Janke Bosque
Gabriel Henrique de Oliveira Caetano
Pedro Henrique Campelo
Vitor Hugo Gomes Lacerda Cavalcante
Pedro de Podestà Uchôa de Aquino
Tânia Andrade de Queiroz
Almir de Paula
Luisa Maria Diele-Viegas
Suelem Muniz Leão
Roger Maia Dias Ledo
Marcella Gonçalves Santos
Yan Felipe Figueira Soares
Mariana Mira Vasconcellos
Laís Batista Alvarenga Veludo
Cecília Rodrigues Vieira

A COVID-19 provocou uma grave crise de proporções mundiais, sem precedentes nesse século (WHO, 2020). Alguns governos, o setor produtivo e a sociedade em geral buscam informações e soluções de curto prazo para enfrentar e mitigar os impactos causados pela pandemia (ANDERSON et al., 2020). Para o efetivo sucesso das ações de combate e mitigação, é necessário o entendimento da difusão da doença, tanto na escala temporal como espacial (SHINDE et al., 2020). Entretanto, existem três importantes lacunas para o rápido desenvolvimento de modelos acurados da difusão da Covid-19 no Brasil: (1) o

¹ Coordenador.

acesso às bases de dados relevantes, (2) a identificação dos principais fatores de risco e (3) o uso de abordagens espaço-temporais para todos os municípios. Apesar da rápida multiplicação de modelos preditivos do crescimento do número de infectados, são incipientes as abordagens espaço-temporais para prever, no curto prazo, as regiões de maior risco.

Propomos a modelagem da variação espaço-temporal de casos e óbitos de Covid-19 nos municípios brasileiros, utilizando inferência bayesiana. Devido à natureza dos dados do número de casos e óbitos, bem como ao excesso de zeros, consideramos modelos baseados nas distribuições de Poisson e Binomial Negativa e respectivas versões infladas de zeros. Valores de *Deviance Information Criterion* (DIC) e *Conditional Predictive Ordinate* (CPO) foram considerados para a seleção de modelos. As projeções incluem cada município em intervalos de 30 dias, desde a última atualização dos dados. A *pipeline* foi otimizada para processamento paralelo em *cluster* configurado nas plataformas Microsoft Azure e Google Cloud. A identificação de fatores de risco se baseia em técnicas de *machine learning* (CUTLER et al., 2012) e as projeções foram obtidas através de modelos espaço-temporais utilizando inferência bayesiana por INLA (BLANGIARDO & CAMELETTI, 2015). Com isso, implementamos um sistema de alerta precoce que permite a alocação efetiva de recursos e a adoção de medidas preventivas nas regiões de maior risco, no devido tempo.

Os resultados serão divulgados ao público e poderão ser escalonados com maior detalhamento geográfico (*e.g.*, Distrito Federal) de acordo com a disponibilidade de dados devidamente estruturados. Para a sociedade de maneira geral, nossos resultados auxiliarão na tomada de decisões informadas, sobretudo aquelas relacionadas às condutas de isolamento social em áreas de maior risco de infecção. Para os usuários do poder público, a solução oferecerá predições acuradas para a formulação de políticas públicas. Será útil, também, para subsidiar decisões sobre o direcionamento de recursos e implementação de ações mitigadoras, ao permitir a simulação dos impactos futuros de medidas adotadas no presente. Finalmente, a solução oferece importantes ele-

mentos para a realização de estudos futuros pelo setor acadêmico. Esses estudos poderão focar o refinamento dos modelos, *e.g.*, com a incorporação de análises de sensibilidade ou a otimização dos algoritmos, bem como a investigação dos mecanismos que relacionam os fatores de risco com a difusão do vírus ou de outros organismos.

REFERÊNCIAS

ANDERSON, R. M.; HEESTERBEEK, H.; KLINKENBERG, D.; HOLLINGSWORTH, T. D. How will country-based mitigation measures influence the course of the COVID-19 epidemic? **Lancet**. 395, 931-934. doi: 10.1016/s0140-6736(20)30567-5. 2020.

BLANGIARDO, M.; CAMELETTI, M. **Spatial and Spatio-temporal Bayesian Models with R-INLA**. Chichester, UK: John Wiley & Sons, Ltd. 2015.

CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. Random forests. *In*: ZHANG, C.; Y, M. A. **Ensemble Machine Learning: Methods and Applications**. New York: Springer Science+Business Media. 2012.

SHINDE, G. R.; KALAMKAR, A. B.; MAHALLE, P. N.; DEY, N.; CHAKI, J.; HASSANIEN, A. E. Forecasting models for coronavirus (COVID-19): A survey of the state-of-the-art. **SN Computer Science**. 1-35. 2020

WORLD HEALTH ORGANIZATION (WHO). **Coronavirus disease 2019 (COVID-19) Situation Report – 97**. 2020.

PALAVRAS-CHAVE: Covid-19; aprendizado de máquina modelagem; epidemiológica; R-INLA; variáveis preditoras.