

# Modelando a expansão espacial e temporal da COVID-19 em Goiás: lições para subsidiar políticas públicas

*Modeling spatial and temporal expansion of COVID-19 in Goiás State: lessons for advising health policies*

Thiago Fernando Rangel<sup>1</sup> , José Alexandre Felizola Diniz-Filho<sup>1</sup> , Cristiana M Toscano<sup>2</sup> 

No contexto da expansão global da pandemia da COVID-19, modelos preditivos se tornaram uma ferramenta fundamental para auxiliar a subsidiar políticas públicas para a mitigação dos efeitos da pandemia<sup>(1)</sup>. Os modelos epidemiológicos clássicos da classe SIR (Suscetíveis, Infectados e Recuperados) e suas variações vêm sendo muito utilizados<sup>(2)</sup> nesse contexto e indicadores relacionados à transmissão da doença na população, como o número reprodutivo  $R^3$ , antes discutidos exclusivamente por cientistas, passaram a ser de conhecimento público e veiculados frequentemente na imprensa.

Embora os modelos SIR possam ser facilmente implementados de forma analítica, modelos mais complexos que avaliam a progressão da doença em nível individual ao longo do tempo são mais realistas<sup>(4)</sup>. Esses modelos, denominados modelo baseado em indivíduos ou modelos baseado em agente (ABM, do inglês *Agent-Based Model*), são particularmente úteis pela facilidade de incorporar a heterogeneidade de uma população e permitir a avaliação de intervenções em cenários complexos<sup>(5)</sup>. Por outro lado, são mais difíceis de serem calibrados e ajustados a dados empíricos e exigem uma grande capacidade computacional para sua implementação<sup>(6)</sup>. Aplicar esses modelos dinâmicos complexos exige uma integração interdisciplinar envolvendo cientistas de diferentes áreas.

Nesse contexto, com a chegada da pandemia da COVID-19 ao Brasil no início de 2020 e, mais especificamente, em Goiás a partir de março, desenvolvemos um ABM capaz de avaliar a dinâmica espacial e temporal da epidemia no

estado. O modelo ABM-COVID-GO desenvolvido pelo grupo da UFG (ver [www.covid.bio.br](http://www.covid.bio.br)) simula a progressão da COVID-19 considerando cada indivíduo de uma população de suscetíveis em uma arcabouço metapopulacional, no qual o Estado de Goiás é um população e cada um dos municípios, com suas particularidades demográficas (especialmente estrutura etária) é uma subpopulação. No modelo, os indivíduos em cada município vão gradualmente se infectando a partir da dinâmica interna e de suas relações geográficas e demográficas. O modelo simula a progressão da doença a partir de diversos parâmetros e suas distribuições estatísticas, entre eles o período de incubação, tempo e período de transmissibilidade, proporção de indivíduos infectados que desenvolvem sintomas, probabilidades de progressão para quadros mais graves requerendo hospitalização, internação em UTI e probabilidade de evolução para óbito, estratificados por grupos etários. Assim, a partir do número e transmissão de infecções na população é possível estimar progressivamente o número de eventos (pessoas internadas em hospital e UTI, e óbitos por COVID-19) e a demanda por leitos hospitalares a cada momento, já considerando o tempo de hospitalização médio. É importante ressaltar que os modelos projetam o número efetivo de eventos, independentemente de problemas de subnotificação ou relacionados ao atraso nos sistemas de informação ou confirmação de casos ou óbitos.

O principal parâmetro relacionado à progressão de uma epidemia é o número reprodutivo básico ( $R_0$  no início da epidemia) que representa o número médio de infecções

<sup>1</sup>Instituto de Ciências Biológicas (ICB), Universidade Federal de Goiás – Goiânia (GO). Brasil. E-mails: [thiago.rangel@ufg.br](mailto:thiago.rangel@ufg.br), [diniz@ufg.br](mailto:diniz@ufg.br)

<sup>2</sup>Instituto de Patologia Tropical e Saúde Pública (IPTSP), Universidade Federal de Goiás – Goiânia (GO). Brasil. E-mails: [ctoscano@ufg.br](mailto:ctoscano@ufg.br)

**Como citar este artigo:** Rangel TF, Diniz-Filho JAF, Toscano CM. Modelando a expansão espacial e temporal da COVID-19 em Goiás: lições para subsidiar políticas públicas. Rev. Eletr. Enferm. [Internet]. 2020 [acesso em: \_\_\_\_\_];22:65464. Disponível em: <https://doi.org/10.5216/ree.v22.65464>.

secundárias que um indivíduo infectado gera em uma população de suscetíveis<sup>(7)</sup>. Esse número diminui com a redução gradual do número de suscetíveis na população e, especialmente, em função das medidas de intervenção implementadas ao longo do tempo, caracterizando o  $R$  efetivo ( $Re$ ). No ABM-COVID-GO III o  $Re$  é estimado diretamente a partir do índice de isolamento social medido por telefonia móvel e gerado pela *inloco* (<https://mapabrasileirodacovid.inloco.com.br/pt/>) para cada município de Goiás. A relação entre isolamento social e o  $Re$  tem sido assumida em diversos trabalhos, sendo uma função inversa da implementação de medidas de distanciamento social<sup>(8)</sup>. Os valores estimados empiricamente utilizando o pacote *EpiEstim* e considerando os casos confirmados de COVID-19 no Estado de Goiás têm forte correlação com o índice de isolamento social, considerando um atraso temporal de sete dias entre o isolamento e a geração de casos ( $r=-0,72$ ). Isso é importante para validar dos pressupostos do ABM-COVID-GO e mostra, ao mesmo tempo, a necessidade de se manter o isolamento social, em adição à outras medidas não farmacológicas recomendadas como diagnóstico e isolamento de casos; e rastreamento e quarentena de contatos, para mitigar os impactos da COVID-19.

Tem sido possível melhorar gradativamente a calibração do modelo a partir de dados locais, de modo a reconstruir de forma mais acurada a progressão da curva de crescimento de eventos de hospitalização e óbitos por COVID-19 em Goiás. Entre eles, consideramos as estimativas de prevalência de infecção obtidas dos inquéritos sorológicos de base populacional realizados Goiânia (0,75% e 2,1% em 30/05 e 20/06, respectivamente<sup>(9)</sup>), e o número de pacientes com COVID-19 internados em Goiânia.

Um modelo bem calibrado significa que foi possível capturar de forma acurada as principais tendências passadas e, usando um raciocínio indutivo, pode-se projetar os eventos no futuro sob diferentes cenários. Isso pode ser feito considerando diferentes níveis de isolamento sociais no futuro ou avaliando cenários contrafactuais (como, por exemplo, avaliar o que teria ocorrido caso nenhuma medida tivesse sido implementada). Com diferentes cenários é possível obter projeções contrastantes de eventos e demanda de leitos hospitalares de pacientes com COVID-19 no futuro. Por exemplo, considerando os baixos níveis isolamento social em junho de 2020, que se refletiriam em um  $Re$  elevado entre 1,4 e 1,5, projeta-se um número extremamente elevado de óbitos (da ordem de 18.000) em longo prazo. Embora cenários de crescimento contínuo de longo prazo em geral não se concretizem, uma vez que medidas para reduzir as transmissões são implementadas em caráter emergencial em função do colapso do sistema de saúde, a percepção da magnitude dos eventos acumulados derivados de um crescimento *quasi*-exponencial em longo prazo pode ser útil uma vez que serve como um alerta da necessidade da

adoção de medidas mais rigorosas para o combate à epidemia. Por outro lado, considerando a dificuldade de um novo período prolongado de quarentena, pode-se testar o efeito de cenários alternativos, como por exemplo um cenário de implementação intermitente de medidas de distanciamento mais rigorosas (com ciclos de 14 dias, por exemplo), que reduziria em até 61,5% o número de óbitos em longo prazo. Mais importante, quando consideramos uma estratégia adicional de reforço significativo da vigilância epidemiológica no sentido de implementar o rastreamento e quarentena de contatos de casos para interromper as cadeias de transmissão secundárias há um impacto adicional de cerca de 15% na redução de hospitalização e óbitos por COVID-19 a longo prazo<sup>(10)</sup>. Sem dúvida a realidade é bem mais complexa do que qualquer um desses cenários e, claro, a efetividade de qualquer medida adotada depende de uma série de fatores, especialmente a adesão da população e da sociedade e de condições efetivas para implementar e manter esse tipo de estratégia ao longo do tempo.

Em resumo, a aplicação de um ABM para avaliar a progressão da COVID-19 tem sido útil para entender a progressão da doença e subsidiar políticas públicas no município de Goiânia e no Estado de Goiás, tendo sido sistematicamente apresentadas, discutidas e validadas pelo Comitê de Operações de Emergência em Saúde Pública (COE) do Estado de Goiás e do município de Goiânia. Vale a pena ressaltar que responder à pergunta “o que pode acontecer?” é diferente de responder à pergunta “o que deve ser feito?”. Modelos respondem à primeira pergunta e neste sentido podem ser úteis para instrumentalizar aqueles que precisam responder à última pergunta. A definição de o que deve ser feito cabe ao gestor em articulação com os poderes públicos, agências de saúde pública e a sociedade.

## REFERÊNCIAS

1. Jewell NP, Lewnard JA, Jewell BL. Predictive mathematical models of the COVID-19 pandemic: underlying principles and value of projections. *JAMA* [Internet]. 2020 [acesso em: 24 ago. 2020];323(19):1.893-94. <http://doi.org/10.1001/jama.2020.6585>
2. Bjørnstad ON. *Epidemics: models and data using R*. Swiss: Springer; 2018.
3. Ridenhour B, Kowalik JM, Shay DK. Unraveling  $R_0$ : considerations for public health applications. *Am J Public Health*. 2018;108(supl6):S445-S454. <http://doi.org/10.2105/AJPH.2013.301704r>
4. Nepomuceno EG, Aguirre LA, Takahashi RHC. Individual-based model (IBM): an alternative framework for epidemiological compartment models. *Revista Brasileira de Biometria*. 2016;34(1):133-62.

5. Pitman R, Fisman D, Zaric GS, Postma M, Kretzschmar M, Edmunds J, et al. Dynamic transmission modeling: a report of the ISPOR-SMDM modeling good research practices task force working group–5. *Med Decis Making*. 2012;32(5): 712-21. <http://doi.org/10.1177/0272989X12454578>
6. Miksch F, Jahn B, Espinosa KJ, Chhatwal J, Siebert U, Popper N. Why should we apply ABM for decision analysis for infectious diseases?—An example for dengue interventions. *PLOS One*. 2019;14(8):e0221564. <http://doi.org/10.1371/journal.pone.0221564>
7. Van den Driessche P. Reproduction numbers of infectious disease models. *Infect Dis Model*. 2017;2(3):288-303. <http://doi.org/10.1016/j.idm.2017.06.002>
8. Badr HS, Du H, Marshall M, Dong E, Squire MM, Gardner LM. Association between mobility patterns and COVID-19 transmission in the USA: a mathematical modelling study. *The Lancet Infectious Diseases*, 2020. [http://doi.org/10.1016/S1473-3099\(20\)30553-3](http://doi.org/10.1016/S1473-3099(20)30553-3).
9. Secretaria Municipal de Saúde de Goiânia [Internet]. Acesso em: 24 ago. 2020. Disponível em: <https://www.goiania.go.gov.br/pesquisa-aponta-que-31-838-mil-pessoas-ja-foram-infectadas-por-covid-19-em-goiania/>.
10. Rangel TF, Diniz-Filho JAF, Toscano CM. Modelagem da expansão espaço-temporal da COVID-19 em Goiás. Nota Técnica 7: atualização das projeções até 31 de agosto de 2020. [Internet]. Goiânia: UFG; INCT; ICB; IPTSP; 2020. [acesso em: 24 ago. 2020]. Disponível em: [www.covid.bio.br](http://www.covid.bio.br).

