

Análise do modelo logístico aplicado à primeira onda da Covid-19 nos países com os 20 maiores PIB'S

Analysis of the logistic model applied to the first wave of Covid-19 in countries with the 20 largest GDP'S

Lucas Cardoso de Souza¹ , Kelsner de Souza Kock² 

1. Discente do curso de Medicina pela Universidade do Sul de Santa Catarina (UNISUL), Campus Tubarão. Tubarão, SC, Brasil. 2. Docente dos cursos de Fisioterapia, Matemática e Medicina da Universidade do Sul de Santa Catarina (UNISUL), Campus Tubarão, Tubarão, SC, Brasil.

Resumo

Objetivo: aplicar a modelagem logística da primeira onda da COVID-19, com índice nos países com 20 maiores Produto Interno Bruto (PIB). **Métodos:** foi utilizada a modelagem matemática de crescimento logístico, considerando os seguintes parâmetros: número cumulativo de casos (C), tamanho final da epidemia na onda única de um surto (K), taxa intrínseca de crescimento (γ) e tempo de inflexão (τ). **Resultados:** o Brasil apresentou maior número de casos e mortalidade, e os Estados Unidos da América (EUA) maior número de casos absolutos. A Coreia do Sul evidenciou o menor ponto de inflexão de 15,3 dias, enquanto o maior foi da Indonésia, com 213,9 dias. Na análise entre o ponto de inflexão e casos acumulados (/100 mil habitantes), observou-se correlação positiva moderada significativa ($r=0,629$ e $p=0,003$); ($r=0,532$ e $p=0,016$). **Conclusão:** o reconhecimento do comportamento de uma epidemia por meio da modelagem matemática torna possível determinar a propagação de uma epidemia, visto que, com a possibilidade de captar a dinâmica de uma epidemia, torna-se possível prever a necessidade de medidas públicas antecipadas e, conseqüentemente, diminuição da mortalidade global.

Palavras-chave: Infecções por Coronavírus; COVID-19; Simulação por Computador; Pandemia.

Abstract

Objective: to apply logistic modeling of the first wave of COVID-19 in countries with the 20 highest Gross Domestic Product (GDP). **Methods:** logistic growth mathematical modeling was used, considering the following parameters: cumulative number of cases (C), the final size of the epidemic in the single wave of an outbreak (K), intrinsic growth rate (γ), and inflection time (τ). **Results:** Brazil showed the highest number of cases and mortality, and the United States of America (USA) had the highest number of absolute cases. South Korea showed the lowest inflection point of 15.3 days, while the highest infection point was Indonesia, with 213.9 days. In the analysis between the inflection point and cumulative cases (/100,000 population), a moderate significant positive correlation was observed ($r=0.629$ and $p=0.003$); ($r=0.532$ and $p=0.016$). **Conclusion:** the recognition of the behavior of an epidemic through mathematical modeling makes it possible to determine the spread of an epidemic, since, with the possibility of capturing the dynamics of an epidemic, it becomes possible to predict the need for anticipated public measures and, consequently, decrease in overall mortality.

Keywords: Coronavirus Infections; COVID-19; Computer Simulation; Pandemics.

INTRODUÇÃO

COVID-19 é o nome dado à doença causada pelo vírus pertencente ao grupo dos coronavírus humanos (HCoV). Os sintomas mais comuns da doença incluem febre, cansaço e tosse seca. Alguns pacientes podem ter dores no corpo, congestão nasal, corrimento nasal, dor de garganta ou até diarreia. De modo geral, esses sintomas, geralmente, são leves e começam gradualmente, visto que, normalmente, a maioria das pessoas (cerca de 80%) se recupera da doença sem precisar de tratamento hospitalar. As pessoas que necessitam de maior atenção são aquelas classificadas em população de risco por terem maior probabilidade de desenvolver as doenças graves, principalmente idosos e indivíduos com comorbidades associadas¹.

A forma de transmissão ocorre de pessoa para pessoa por meio de pequenas gotículas do nariz ou da boca que se espalham

quando uma pessoa com a doença tosse ou espirra. Essas gotículas podem pousar em objetos e superfícies por algumas horas, facilitando o contágio¹. Além disso, o fato que alguns pacientes podem disseminar o vírus de 24 a 48 horas antes do início dos sintomas e de 3 a 4 semanas após o início dos sintomas, tornando a contaminação em maiores escalas². Acrescentando a maior dificuldade de prevenção, também existe uma fração significativa de casos que permanecem assintomáticos e, mesmo assim, são infectantes³.

Devido ao elevado número de casos, a Organização Mundial da Saúde (OMS) declarou, em 30 de janeiro de 2020, que o surto da doença causada pelo novo coronavírus COVID-19 constitui uma emergência de saúde pública de importância internacional, o mais alto nível de alerta da OMS1, e o primeiro caso relatado e confirmado foi no dia 31 de dezembro de 2019, em Wuhan

Correspondente: Kelsner de Souza Kock. Rua Galdino José de Bessa, 164. Oficinas. Tubarão, SC, Brasil. 88702-220. E-mail: kelsnerkock@yahoo.com.br

Conflito de interesse: Os autores declaram não haver conflito de interesse

Recebido em: 24 Dez 2021; Revisado em: 10 Fev 2021; 7 Mar 2022; Aceito em: 9 Mar 2022

na China⁴. Após a rápida expansão e disseminação do vírus, a epidemia se espalhou de Wuhan para outras áreas. Em 30 de janeiro de 2020, 7734 casos foram confirmados na China, e 90 outros casos também foram relatados em vários outros países com uma taxa de mortalidade calculada em 2,2%⁵. Contudo, outro estudo feito em 16 de fevereiro encontrou uma taxa de mortalidade média de 2,5% que variava nos grandes centros com taxa maior que 3% e em províncias menos afetadas com 0,7%, sugerindo que a sobrecarga nos hospitais está correlacionada com a mortalidade⁶.

Nesta perspectiva, a rápida propagação do COVID-19 e o considerável índice de letalidade, principalmente para a população de risco, são fatores que transformam essa infecção em um problema de saúde e emergencial, causando grande impacto no sistema de saúde¹.

Como instrumento para análise de epidemias, a modelagem matemática pode ser utilizada para estudar suas principais características e estimar os parâmetros epidemiológicos nos surtos de doenças infecciosas. Durante um surto, os parâmetros epidemiológicos cruciais incluem o número de reprodução⁷, tempo de duplicação, tamanho final da epidemia⁸ e o ponto de inflexão⁹. Os três parâmetros refletem os níveis de infecciosidade, gravidade e o tempo de inflexão de uma epidemia, respectivamente¹⁰. O número de reprodução, representado pela letra (R), é o número médio de casos infecciosos secundários produzidos por um caso infeccioso durante um surto de doença. Quando uma população é totalmente suscetível, o R se torna o número básico de reprodução, representando, assim, o R₀. Quando uma doença atinge um local ou região pela primeira vez, o R estimado pode ser tratado como R₀¹¹.

A previsão em tempo real do tamanho final da epidemia é um procedimento no qual as estimativas são valiosas se alcançadas precocemente, pois estima em tempo real a gravidade potencial de uma epidemia em andamento, podendo ser crucial para o controle de doenças e a formulação de políticas de prevenção. O ponto de virada ou ponto de inflexão representado por (τ) é definido como o ponto no tempo em que ocorre a alteração do sinal na taxa de acúmulo de casos, ou seja, muda de crescente para decrescente ou vice-versa. Portanto, τ é o momento em que a trajetória diária ou semanal de incidência começa a declinar, o que significa que a taxa de crescimento extrínseco atinge seu máximo; logo o ponto de virada indica o início de uma fase epidêmica que muda da aceleração para a desaceleração. Portanto, o conhecimento desses parâmetros epidemiológicos resume o padrão temporal de uma epidemia e é útil para entender as características de um surto^{12,13}.

De acordo com essas informações, o presente estudo pretende caracterizar a evolução dos casos dessa enfermidade na primeira onda, enfrentada pelos países com maiores Produto Interno Bruto (PIB), analisando o número cumulativo de casos (C), tamanho final da epidemia (K), taxa intrínseca de crescimento (γ) e tempo de inflexão (τ). Esses dados podem servir para que

políticas de prevenção futuras auxiliem os cuidados de saúde em diferentes perspectivas.

Pelo exposto, o objetivo desta pesquisa foi aplicar a modelagem matemática logística da primeira onda da COVID-19, nos países com os 20 maiores PIBs¹⁴: China, Estados Unidos, Índia, Japão, Alemanha, Rússia, Indonésia, Brasil, Reino Unido, França, México, Itália, Turquia, Coreia do Sul, Espanha, Arábia Saudita, Canadá, Irã, Austrália e Tailândia.

MÉTODOS

Este estudo é observacional do tipo ecológico, com análise dos casos confirmados do vírus COVID-19 nos países com 20 maiores PIB do mundo. Foi utilizado o banco de dados sobre a distribuição do COVID-19 nos países com casos confirmados, disponibilizado pelo *European Centre for Disease Prevention and Control*¹⁵, que contempla as variáveis: data, casos acumulados/100.000 habitantes, casos acumulados/100.000 habitantes em 14 dias, óbitos por Covid-19, países e população estimada. Para os casos acumulados/100.000 habitantes, foram considerados os casos antigos e a adição de casos diários, divididos pela população do país e multiplicados pela constante. Para os casos acumulados/100.000 habitantes em 14 dias, foram considerados os mesmos pressupostos, mas em uma média de 14 dias.

Tendo em vista tratar-se de um estudo tipo censitário, foram excluídos deste estudo apenas os casos confirmados de COVID-19 cujos registros tiverem omissão (dados ignorados ou indisponíveis) nas variáveis de interesse para o estudo. Os países considerados foram Estados Unidos, Brasil, China, Índia, Japão, Alemanha, Rússia, Indonésia, Reino Unido, França, México, Itália, Turquia, Coreia do Sul, Espanha, Arábia Saudita, Canadá, Irã, Austrália e Tailândia. Para a coleta de dados, foram utilizadas as variáveis encontradas no banco de dados sobre a COVID-19 da *European Centre for Disease Prevention and Control*¹⁵. Posteriormente à extração e à tabulação dos dados relacionados às variáveis de importância para a pesquisa no ano de 2020, foi considerado o dia 1 a partir dos 100 primeiros casos, sendo analisado até 240 dias nos 20 maiores PIB do mundo. O término da primeira onda foi considerado como o menor valor, após o primeiro pico de casos acumulados /100.000 habitantes em 14 dias.

Este projeto está delineado como um estudo ecológico, que, por definição, não trabalha sujeitos de pesquisa, mas com agregados populacionais como categoria de análise. Além disso, o banco de dados, que será usado, é aberto, de domínio público, mas não contém informações sobre a identidade dos indivíduos constituintes, que poderiam ser usadas para identificação individual ou rompessem a confidencialidade dos dados.

Pelo exposto, e conforme o contido na Resolução do Conselho Nacional de Saúde (CNS) 510/2016 Artigo 1º, Parágrafo Único Incisos II, III e V, este projeto não se incorpora nos termos da Resolução CNS 466/2012 para registro e análise por Comitês


de Ética em Pesquisa Envolvendo Seres Humanos. Os autores informam que têm conhecimento do conteúdo da Resolução 466/2012 do Conselho Nacional de Saúde, que será usada caso seja necessária qualquer decisão ética para a realização deste projeto. Os pesquisadores expressam que não existem conflitos de interesse entre o tema de pesquisa e seus ofícios ou referentes ao custeamento desta pesquisa.

Foi utilizada a modelagem matemática de crescimento logístico, considerando os seguintes parâmetros: número cumulativo de casos (C), tamanho final da epidemia na onda única de um surto (K), taxa intrínseca de crescimento (γ) e tempo de inflexão (τ), conforme demonstra a equação¹⁶:

$$C(t) = \frac{K}{1 + e^{-\gamma(t-\tau)}}$$

A figura 1 exemplifica três casos de crescimento logístico, C1, C2 e C3, com suas respectivas constantes K1, γ_1 e τ_1 , K2, γ_2 e τ_2 , K3, γ_3 e τ_3 . Nesta figura, pode-se observar que $K_1=K_2=K_3$, $\gamma_2 > \gamma_1 = \gamma_3$ e $\tau_3 > \tau_1 = \tau_2$.

Figura 1. Exemplo de modelagem com crescimento logístico



Os dados foram armazenados em um banco de dados criado com o auxílio do software Microsoft Excel. Eles foram apresentados por meio de medidas de tendência central e dispersão. Para resolução da equação logística, foi utilizado o suplemento Solver do Microsoft Excel por meio da solução de minimização do erro por meio do método GRG não linear. Foi realizada correlação de Pearson entre o ponto de inflexão e casos acumulados, considerando erro alfa < 5%.

RESULTADOS

Os resultados do presente estudo demonstraram que o Brasil apresentou o maior número de casos e mortalidade para cada 100.000 habitantes, com valores, respectivamente, de 2.683,8 e 76,9. Em contrapartida, a Tailândia exibiu os menores valores, 4,5 casos para cada 100.000 habitantes de 4,5 e mortalidade de 0,1 para cada 100.000 habitantes. Como relação à evolução temporal da primeira onda da COVID-19, os maiores períodos foram nos EUA, Brasil, Índia e Indonésia, com 240 dias, enquanto a menor onda ficou com a Austrália com 97 dias. Maiores informações podem ser visualizadas na figura 2.

Na figura 3, são apresentados os parâmetros da equação logística para os 20 países com maior PIB. Destaques para a Coreia do Sul, que evidenciou o menor ponto de inflexão de 15,3 dias, enquanto o maior foi da Indonésia com 213,9 dias. A maior taxa intrínseca foi da China de 21,64%, e a menor foi a dos EUA com 2,27%. A figura 2 também exemplifica as curvas dos casos acumulados de COVID-19 do Brasil e Alemanha com a curva do modelo logístico.

Na análise entre o ponto de inflexão, casos acumulados e casos acumulados (/100 mil habitantes), foi observada a correlação positiva moderada significativa ($r=0,629$ e $p=0,003$); ($r=0,532$ e $p=0,016$). (Figura 4)

Figura 2. Evolução temporal da primeira onda da COVID-19, número de casos e mortalidade para cada 100.000 habitantes nos países com 20 maiores PIB do mundo.

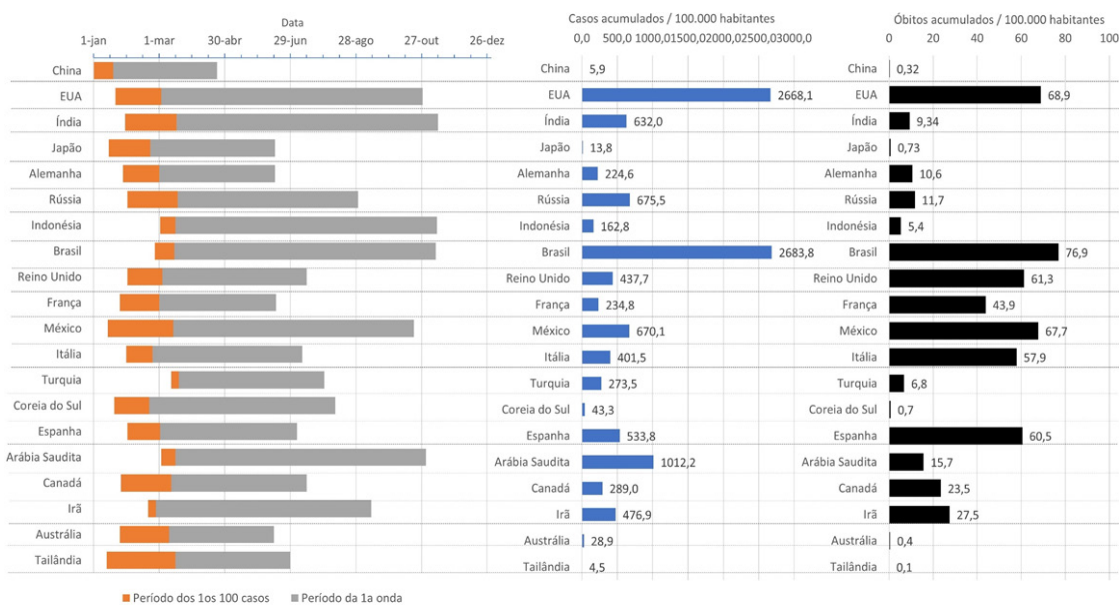


Figura 3. Parâmetros da equação logística e exemplos de associação dos casos acumulados de COVID-19 e modelo logístico no Brasil e Alemanha.

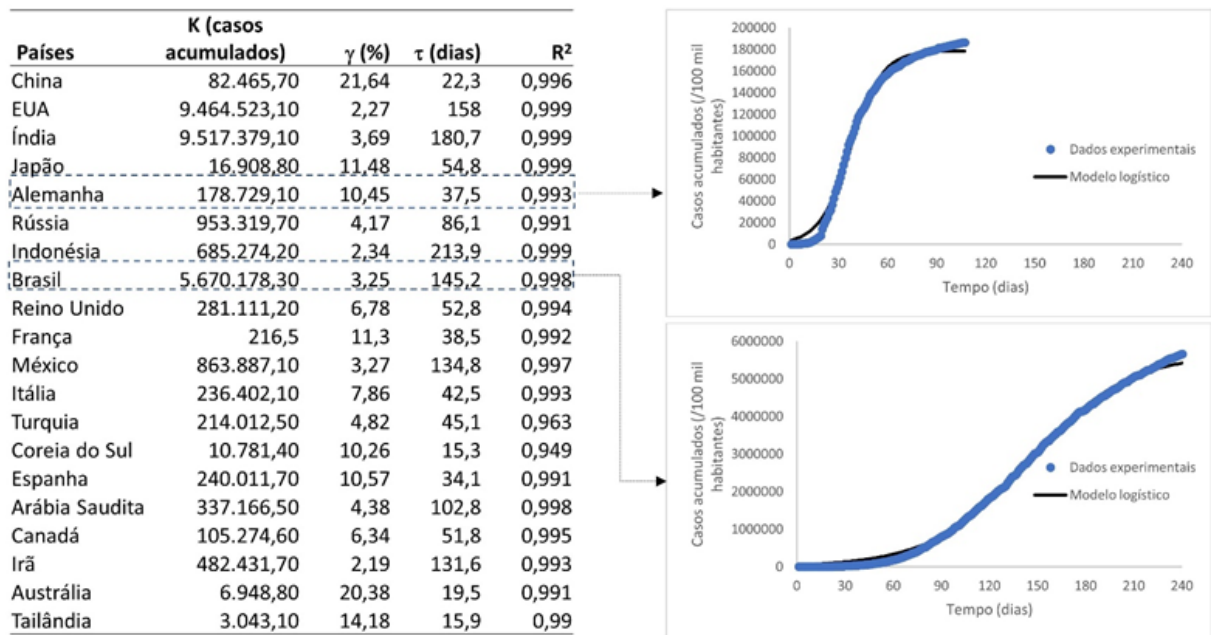



Figura 4. Correlação entre o ponto de inflexão e os casos acumulados.



DISCUSSÃO

Os resultados do presente estudo demonstraram que a modelagem matemática, por meio da regressão logística, demonstrou alta correlação e estimativa fidedigna sobre os principais parâmetros críticos da 1ª onda da pandemia de COVID-19. Com essa análise, é possível analisar o crescimento do contágio e projetar estratégias e políticas para gerenciar a propagação da epidemia antecipadamente.

Outros estudos apresentam análise similar¹⁸⁻²¹, no qual reconhece que países com maior rigorosidade nas medidas de prevenção, como a China e nos países com medidas preventivas nos casos iniciais, como a Coreia do Sul, tiveram menor número de casos acumulados (K), menor tempo de inflexão (τ) e mortalidade. Como no estudo que analisou a progressão dos casos confirmados de COVID-19, após a implantação das medidas de controle sobre a transmissão do novo coronavírus e como a curva dos casos acumulados iria se comportar¹⁸.

Outro estudo com resultados similares foi o que utilizou o modelo FbProphet. Ele cria um modelo logístico, utilizando aprendizado de máquina (machine learning), que possuem redes neurais artificiais, árvores de decisões e redes Bayesianas, na tentativa de a curva logística possuir uma previsão de acordo com o mundo real¹⁹.

Outros estudos também podem ser citados, como análise da equação logística da atual pandemia na Suíça, Holanda, Itália, Turquia e Coreia do Sul²⁰, e modelo logístico da pandemia por COVID-19 na Índia²¹.

Comparando a outro estudo, os Estados Unidos da América, que produziram uma curva logística na análise da primeira onda de COVID-19, no qual o modelo criado avaliou apenas duas semanas, na tentativa de abranger, aproximadamente, o período de incubação. No entanto, a avaliação de um período tão curto não encontrou valores fidedignos para número de casos e mortalidade. Os pesquisadores reconhecem que diferenças em taxa de crescimento, subnotificação e poucos casos iniciais, tornaram duas semanas um curto período de tempo e não produziu uma curva confiável. Diferente do presente estudo, que analisou a redução ou término da 1ª onda para realizar a modelagem e, assim, encontrar alta correlação entre dados experimentais e modelo logístico²².

Entre os países com maior número de casos, destaca-se o Brasil, sendo explicado por estratégias de enfrentamentos mais tardias¹⁸. Os estados com maior número de casos no Brasil foram São Paulo e Rio de Janeiro. No caso do Rio de Janeiro, o isolamento social foi iniciado dia 17/3/2020 com a suspensão das aulas no dia anterior e, em São Paulo, o isolamento social iniciou dia 18/3/2020 com a suspensão das aulas apenas dia 23/3/2020. Na Itália, a suspensão das aulas se iniciou dia 4/3/2020, quando já se contabilizavam 3.089 casos; o fechamento das fronteiras ocorreu dia 7/3/2020 com 5.883 casos, e a implantação da quarentena no dia 9/4/2020, com

9.172 casos; desse modo, as medidas preventivas se iniciaram tardiamente como fator para reduzir a eficácias das medidas. Pelo contrário, a Coreia do Sul apresentou um dos países com menor número de casos pelo fato de ter adotado de forma precoce estratégias preventivas, como proibição de passageiros oriundos de Hubei, dia 4/2/2020, quando o país apresentava apenas 16 casos e publicação oficial do isolamento social no dia 20/2/2020 com apenas 104 casos¹⁸.

A maneira de enfrentamento dos diversos países ocorreu de diversas formas. A China teve atitudes mais rígidas, adotou regime de isolamento no final de janeiro, quando existiam 199 casos confirmados, o que resultou em uma desaceleração expressiva na propagação^{18,22,23}.

A evolução do 1º caso até os 100º demonstra que, quanto maior é esse intervalo, mais efetiva foram a restrições, tornando, assim, esse valor uma forma de estimativa. Contudo, observa-se uma desvantagem nos países que foram afetados primeiro, visto que muitos países não estavam preparados para lidar com a magnitude da pandemia. Em um estudo feito, analisando os países europeus, foi demonstrado que, quanto mais tarde um país atingiu 10 infecções conhecidas, mais tempo em média demorou para atingir 1.000 casos conhecidos²³.

Quanto à mortalidade, houve discrepantes resultados nos diferentes países. Em um estudo²⁴ ecológico, que analisou a primeira onda pandêmica da COVID-19 em 37 países, identificou-se que o Brasil alcançou número de mortos de 76,9 para cada 100.000 habitantes, enquanto, na Tailândia, o número de mortos foi de 0,1 para cada 100.000 habitantes e na Austrália 0,4 para cada 100.000 habitantes. A grande variação nas taxas de mortalidade pode ser atribuída à variação nas taxas de testes, subnotificação ou diferenças reais nos parâmetros ambientais, socioeconômicos e do sistema de saúde²⁴.

De acordo com este estudo, alguns parâmetros críticos do modelo são identificados, como o valor total de casos acumulados (K), a taxa percentual de aumento de casos (gama) e o ponto de inflexão ou virada em dias (tau) da primeira onda da pandemia. O valor de K do modelo logístico foi muito similar ao total de casos acumulados, observados ao término da análise, indicando que a curva logística é uma boa representação do contágio pela COVID-19, corroborado o valor de R^2 .

A taxa de crescimento apresentou valores entre 2,19% (EUA) e 21,64% (China) neste estudo, como em outro entre 14% e 22%, demonstrando a variabilidade de evolução da COVID-19 nos países avaliados²⁵.

O ponto de inflexão parece ser um bom parâmetro de análise, pois se indica o fim do aumento exponencial dos casos. Os valores de tau variaram de 15,3 a 213,9 dias, como em outros trabalhos com 19,1 na China, 37,8 no Irã e 31,3 dias em Taiwan, como demonstrado em uma pesquisa de modelagem logística realizada em países da Ásia. Os países com menor ponto de

inflexão não alcançaram número de casos tão altos²⁵.

Os países que obtiveram maior número de casos acumulados demonstraram características, como medidas preventivas sociais tardias e ineficazes, muitos números de casos iniciais, maior ponto de inflexão. Em contrapartida, os países com menor número de casos acumulados possuíam atitudes praticamente invertidas, por exemplo, ações tomadas no início da pandemia, quando o número de casos era menor, isolamento social efetivo, menor duração do ponto de inflexão, testes iniciais realizados de forma maciça para identificar casos assintomáticos, além da cultura^{18,24}.

Em se tratando da correlação entre o ponto de inflexão (tau) e casos acumulados, foi demonstrada associação positiva significativa, pois, quanto maior o período de permanência de uma epidemia, maior são os números de casos e, consequentemente, de mortalidade. Desse forma, essa ferramenta se torna importante para compreender a pandemia de forma mais ampla^{24,25}.

Como limitação do estudo, pode-se apontar a utilização de dados secundários e a inferência de resultados por meio de conglomerados. Por esses motivos, algumas dificuldades devem ser elencadas, como falsos positivos e falsos negativos dos testes para COVID-19, condições associadas ao controle administrativo, comportamento social, como a migração, a causa de a morte não ser por COVID-19 e a não inclusão de um grupo por faixa etária, visto que os idosos, os adultos e as

crianças possuem diferente desfecho.

CONCLUSÃO

Este estudo fornece dados importantes para compreender o impacto de uma epidemia sobre um país por meio do número de casos acumulados, da taxa de crescimento e do ponto de inflexão. Neste estudo, é possível caracterizar a evolução dos casos de COVID-19, na perspectiva da modelagem logística nos 20 países com maior PIB do mundo.

O estudo demonstra que as políticas governamentais e o comportamento humano teriam um grande efeito na trajetória dos óbitos causados pela COVID-19, em vista que os países com menor número de reprodução e ponto de inflexão, alcançado pelas medidas de controle mais rígidas, proporcionaram menos pressão ao sistema de saúde e, consequentemente, menor mortalidade.

Ao analisar o número de casos, observa-se que o modelo logístico proposto ofertou grande precisão na análise estatística. Outro fato está na comprovação da relação positiva entre ponto de inflexão e número de casos, por isso que a desaceleração da epidemia é de suma importância. Conclui-se que a confecção da análise matemática torna possível determinar a propagação de uma epidemia em diferentes países, mesmo que a cultura, a população e as estimativas sejam diferentes, visto que, com o modelo logístico, é possível captar a dinâmica de uma epidemia.

REFERÊNCIAS

1. Organização Pan-Americana de Saúde. Folha informativa sobre COVID-19 [Internet]. Brasília: OPAS; 2020 [cited 2020 May 31]. Available from: https://www.paho.org/bra/index.php?option=com_content&view=article&id=6101:folha-informativa-novo-coronavirus-2019-ncov&Itemid=875.
2. Heymann DL, Shindo N. COVID-19: what is next for public health? *Lancet*. 2020 Feb; 395(10224): 542–5. doi: 10.1016/S0140-6736(20)30374-3.
3. Mizumoto K, Kagaya K, Zarebski A, Chowell G. Estimating the Asymptomatic Proportion of 2019 Novel Coronavirus onboard the Princess Cruises Ship, 2020. *Euro Surveill*. 2020 Mar; 2020; 25(10): 2000180. doi: 10.2807/1560-7917.ES.2020.25.10.2000180.
4. Zhao S, Lin Q, Ran J, Musa SS, Yang G, Wang W, et al. Preliminary estimation of the basic reproduction number of novel coronavirus (2019-nCoV) in China, from 2019 to 2020: A data-driven analysis in the early phase of the outbreak. *Int J Infect Dis*. 2020 Mar; 92: 214–7. doi: 10.1016/j.ijid.2020.01.050.
5. Bassetti M, Vena A, Giacobbe DR. The novel Chinese coronavirus (2019-nCoV) infections: Challenges for fighting the storm. *Eur J Clin Invest*. 2020 Mar; 50(3): e13209. doi: 10.1111/eci.13209.
6. Yu M, He S, Wu D, Zhu H, Webster C. Examining the multi-scalar unevenness of high-quality healthcare resources distribution in China. *Int J Environ Res Public Health*. 2019 Aug; 16(16): 2813. doi: 10.3390/ijerph16162813.
7. Van Den Driessche P, Watmough J. Reproduction numbers and sub-threshold endemic equilibria for compartmental models of disease transmission. *Math Biosci*. 2002 Nov-Dec; 180: 29–48. doi: 10.1016/S0025-5564(02)00108-6.
8. Arino J, Brauer F, Van Den Driessche P, Watmough J, Wu J. A final size relation for epidemic models. *Math Biosci Eng*. 2007 Apr; 4(2): 159–75. doi: 10.3934/mbe.2007.4.159.
9. Hsieh YH, Ma S. Intervention measures, turning point, and reproduction number for dengue, Singapore, 2005. *Am J Trop Med Hyg*. 2009; 80(1): 66–71. doi: <https://doi.org/10.4269/ajtmh.2009.80.66>.
10. Tizzoni M, Bajardi P, Poletto C, Ramasco JJ, Balcan D, Gonçalves B, et al. Real-time numerical forecast of global epidemic spreading: Case study of 2009 A/H1N1pdm. *BMC Med*. 2012 Dec; 10: 165. doi: 10.1186/1741-7015-10-165.
11. Wallinga J, Lipsitch M. How generation intervals shape the relationship between growth rates and reproductive numbers. *Proc Biol Sci*. 2007 Feb; 274(1609): 599–604. doi: 10.1098/rspb.2006.3754.
12. Sebrango-Rodríguez CR, Martínez-Bello DA, Sánchez-Valdés L, Thilakarathne PJ, Del Fava E, Van Der Stuyft P, et al. Real-time parameter estimation of Zika outbreaks using model averaging. *Epidemiol Infect*. 2017 Aug; 145(11): 2313–23. doi: 10.1017/S0950268817001078.
13. Carlos del Rio M, Preeti N, Malani M, MSJ. 2019 Novel Coronavirus—Important Information for Clinicians. *JAMA*. 2020 Mar; 323(11): 1039–1040. doi: 10.1001/jama.2020.1490.
14. CIA. Country Comparison: GDP (Purchasing Power Parity) [Internet]. Central Intelligence Agency. 2018. [cited 2020 May 31]. Available from: <https://www.cia.gov/the-world-factbook/field/real-gdp-purchasing-power-parity/country-comparison>.
15. European Centre for Disease Prevention and Control ECDC. Download today's data on the geographic distribution of COVID-19 cases worldwide; 2020. [cited 2020 May 31]. Available from: <https://www.ecdc.europa.eu/en/publications-data/download-todays-data-geographic-distribution-covid-19>.

7 Modelo logístico aplicado à COVID-19

cases-worldwide.

16. Chowell G, Viboud C, Simonsen L, Moghadas SM. Characterizing the reproduction number of epidemics with early subexponential growth dynamics. *J R Soc Interface*. 2016 Oct; 13(123): 20160659. doi: 10.1098/rsif.2016.0659.

17. Zhao S, Musa SS, Fu H, He D, Qin J. Simple framework for real-time forecast in a data-limited situation: The Zika virus (ZIKV) outbreaks in Brazil from 2015 to 2016 as an example. *Parasit Vectors*. 2019 Jul; 12(1): 344. doi: <https://doi.org/10.1186/s13071-019-3602-9>.

18. Antunes BB, Peres IT, Baião FA, Ranzani OT, Bastos LS, da Silva AA, et al. Progressão dos casos confirmados de COVID-19 após implantação de medidas de controle. *Rev bras ter intensiva*. 2020 Jun; 32(2): 213-223. doi: <https://doi.org/10.5935/0103-507X.20200028>.

19. Wang P, Zheng X, Li J, Zhu B. Prediction of epidemic trends in COVID-19 with logistic model and machine learning technics. *Chaos Solitons Fractals*. 2020 Oct; 139: 110058. doi: 10.1016/j.chaos.2020.110058.

20. Pelinovsky E, Kurkin A, Kurkina O, Kokoulina M, Epifanova A. Logistic equation and COVID-19. *Chaos Solitons Fractals*. 2020 Nov; 140: 110241. doi:

10.1016/j.chaos.2020.110241.

21. Singh BP. Modeling and forecasting the spread of COVID-19 pandemic in India and significance of lockdown: A mathematical outlook. *Handbook Statistics*. 2021; 44: 257-289. doi: <https://doi.org/10.1016/bs.host.2020.10.005>.

22. Chen DG, Chen X, Chen JK. Reconstructing and forecasting the COVID-19 epidemic in the United States using a 5-parameter logistic growth model. *Glob Health Research Policy*. 2020; 25(5):1-7. doi: 10.1186/s41256-020-00152-5.

23. Plumper T, Neumayer E. Lockdown policies and the dynamics of the first wave of the Sars-CoV-2 pandemic in Europe [Internet]. *J Eur Public Policy*. 2020 Nov; 29(3): 321-341. doi: 10.1080/13501763.2020.1847170.

24. Pana TA, Bhattacharya S, Gamble DT, Pasdar Z, Szlachetka WA, Perdomo-Lampignano JA, et al. Country-level determinants of the severity of the first global wave of the COVID-19 pandemic: an ecological study. *BMJ Open*. 2021 Feb; 11(2): e042034. doi: 10.1136/bmjopen-2020-042034.

25. Aviv-Sharon E, Aharoni A. Generalized logistic growth modeling of the COVID-19 pandemic in Asia. *Infect Dis Model*. 2020 Jul; 5: 502-509. doi: 10.1016/j.idm.2020.07.003.

How to cite this article/Como citar este artigo :

Souza LC, Kock KS. Análise do modelo logístico aplicado à primeira onda da Covid-19 nos países com os 20 maiores PIB'S . *J Health Biol Sci*. 2022; 10(1):1-7.