

Impactos da pandemia da COVID-19 sobre os planos de saúde no sudeste brasileiro: uma análise de séries temporais interrompidas

Leonardo Biazoli^{1†}, Izabela R. C. Oliveira²

¹Universidade Federal de Alfenas (UNIFAL-MG).

²Universidade Federal de Lavras (UFLA).

Resumo: A análise de séries temporais interrompidas é a abordagem quase experimental a fim de avaliar os efeitos de intervenções discretas em dados longitudinais. Assim, uma série temporal de um determinado resultado de interesse é usada para estabelecer uma tendência subjacente, que é "interrompida" por uma intervenção em um ponto conhecido no tempo. O cenário hipotético em que a intervenção não ocorreu e a tendência continua inalterada é referido como o 'contrafactual'. Este cenário contrafactual fornece uma comparação para a avaliação do impacto da intervenção, examinando qualquer mudança que ocorra no período pós-intervenção. Nesse sentido, o objetivo deste trabalho é analisar os efeitos da pandemia da COVID-19 na contratação de planos de saúde na região Sudeste do Brasil por meio de análise de séries interrompidas. Os dados utilizados referem-se ao número de beneficiários de planos de saúde da região sudeste do primeiro trimestre de 2000 ao primeiro trimestre de 2023 (93 observações), oriundos da Agência Nacional de Saúde Suplementar. A partir da análise da série temporal foi ajustado um modelo quadrático para o período anterior ao tratamento (COVID-19) e após o tratamento abordado. Com base nos ajustes destes modelos, foi possível observar que o número de beneficiários de planos de saúde na região sudeste estava reduzindo, porém a intervenção pode ter provocado uma redução mais acentuada, sendo, em média, de 10 mil beneficiários a menos que o previsto sem a intervenção.

Palavras-chave: Modelos quase experimentais; Inferência causal; Coronavírus.

Impacts of the COVID-19 pandemic on health plans in southeastern Brazil: an analysis of interrupted time series

Abstract: Interrupted time series analysis is the quasi-experimental approach to evaluating the effects of discrete interventions on longitudinal data. Thus, a time series of a given outcome of interest is used to establish an underlying trend, which is "interrupted" by an intervention at a known point in time. The hypothetical scenario in which the intervention did not occur and the trend continues unchanged is referred to as the 'counterfactual'. This counterfactual scenario provides a comparison for evaluating the impact of the intervention by examining any changes that occur in the post-intervention period. In this sense, the aim of this work is to analyze the effects of the COVID-19 pandemic on health insurance contracting in the Southeast region of Brazil by means of interrupted series analysis. The data used refers to the number of health insurance beneficiaries in the southeast region from the first quarter of 2000 to the first quarter of 2023 (93 observations), from the National Supplementary Health Agency. Based on the time series analysis, a quadratic model was fitted for the period before the treatment (COVID-19) and after the treatment. Based on the fits of these models, it was possible to observe that the number of health insurance beneficiaries in the southeast was falling, but the intervention may have caused a more pronounced reduction, with an average of 10,000 fewer beneficiaries than predicted without the intervention.

Keywords: Quasi-Experimental models; Causal inference; Coronavirus.

[†]Autor correspondente: leonardobiazoli19@gmail.com.

Introdução

A inferência causal compreende o estudo da relação entre causa e efeito, de modo a determinar os efeitos de uma determinada intervenção em algum resultado. O objetivo da inferência causal é inferir na dinâmica de eventos sob condições de mudanças, como, por exemplo, por intervenções ou tratamentos (Pearl, 2010). Assim, os experimentos podem ser aleatórios ou não aleatórios, como é o caso dos estudos das ciências sociais, que, conforme Rubin (1974), não é viável financeiramente ou até mesmo ético realizar experimentos aleatórios nessa área.

Para os experimentos aleatórios, os resultados nos grupos de tratamento, em geral, podem ser diretamente comparados, pois suas unidades são semelhantes. No entanto, ao se tratar de experimentos não aleatórios, tais comparações diretas podem ser enganosas porque as unidades expostas a um tratamento, geralmente, diferem sistematicamente das unidades expostas ao outro tratamento (Rosenbaum; Rubin, 1983). Assim, há vários modelos quase-experimentais que são utilizados para estimar os efeitos causais de algum tratamento sobre um determinado resultado, com o intuito de corrigir o viés de seleção, como, por exemplo, *propensity score matching*, controle sintético, diferenças em diferenças e séries temporais interrompidas.

Conforme destacado por Penfold e Zhang (2013), as séries temporais interrompidas (STI) configuram em uma ferramenta simples, mas poderosa a fim de avaliar o impacto de uma mudança de política ou de um programa numa população definida. Essa abordagem deve ser utilizada quando o pesquisador não tem controle sobre a implementação de uma intervenção e quando não é possível fazer a aleatorização do experimento. Portanto, as séries temporais interrompidas consistem, no caso mais simples, em dois segmentos de observações. O primeiro segmento trata-se dos valores obtidos antes da intervenção e o segundo segmento é constituído pelas observações após a intervenção.

A abordagem de séries temporais interrompidas é utilizada em diversas aplicações de avaliação de impacto de intervenção e/ou política. Oliveira *et al.* (2019) e Nascimento *et al.* (2020) utilizaram séries temporais interrompidas para avaliar os efeitos de políticas públicas, respectivamente, sobre a taxa de mortalidade hospitalar por infarto agudo do miocárdio e mortalidade prematura por câncer de colo uterino no Brasil. Em outros estudos, essa técnica foi utilizada para analisar o impacto da “Lei Seca”, sobre a mortalidade por acidentes de trânsito no Brasil (Nunes *et al.*, 2021) e também para analisar os impactos da pandemia da COVID-19 nos serviços de saúde (Irvine *et al.*, 2021; Vinci *et al.*, 2022). Ademais, Figueiredo *et al.* (2022) utilizaram da mesma abordagem para analisar as tendências nas taxas de suicídio no Brasil, no período antes e depois do início da recessão econômica.

O sistema de saúde brasileiro é composto pela saúde pública, saúde complementar e saúde suplementar (BRASIL, 1990). Por sua vez, a saúde suplementar é composta por todas as operadoras de planos de saúde (OPS) e seguradoras de assistência à saúde (BRASIL, 1998), sendo subordinadas à Agência Nacional de Saúde Suplementar (ANS) (BRASIL, 2000).

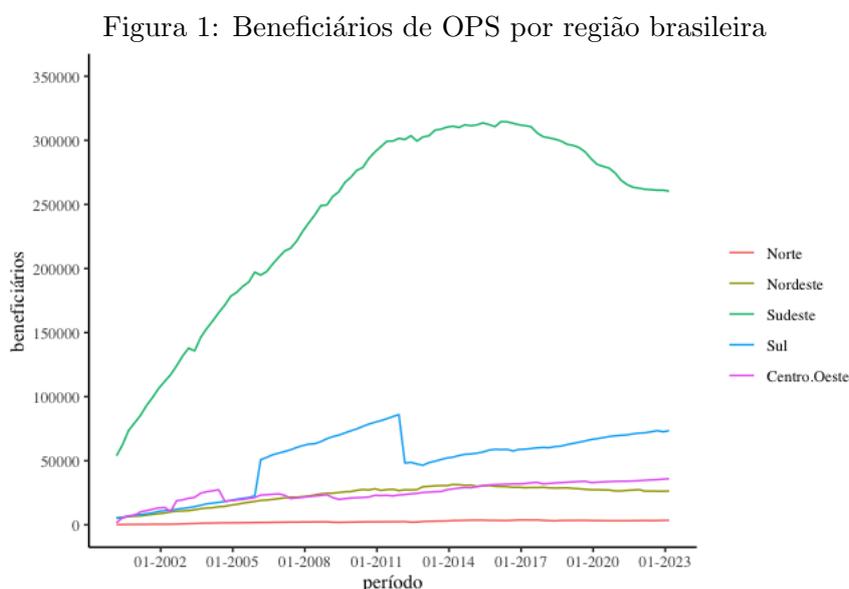
A saúde suplementar brasileira possui 1.141 operadoras de plano de saúde com registro ativo na ANS, com 24.677 planos com registro e comercialização ativa. Assim, o orçamento disponível para esse subsistema depende do número de beneficiários que contratam os planos de saúde, bem como os custos e variações envolvidas no processo. Masques *et al.* (2023) analisaram o desempenho das OPS antes e durante a pandemia da COVID-19, observando que, após início da pandemia, os indicadores de rentabilidade apresentaram uma redução significativa.

Nesse sentido, este trabalho tem como objetivo analisar os efeitos da pandemia da COVID-19 na contratação de planos de saúde na região sudeste do Brasil, a partir de análise de séries temporais interrompidas. Com isso, intenciona-se verificar se o cenário pandêmico trouxe flutuações na demanda por planos de saúde nesta região do Brasil, a partir do ano de 2020.

Materiais e Métodos

Os dados a serem analisados nesta pesquisa foram retirados da base de informações dos beneficiários da Agência Nacional de Saúde Suplementar (ANS). A janela temporal dos dados inicia em janeiro de 2000 e encerra em março de 2023, com intervalos trimestrais. Os dados referem-se ao número de beneficiários de planos de saúde para as cinco regiões do Brasil, com idade acima de 60 anos nos planos de referência.

A Figura 1 mostra a distribuição de beneficiários das OPS, acima de 60 anos nas cinco regiões do país. A partir desta figura é possível observar que a região Sudeste concentra o maior número de beneficiários e apresenta uma tendência de queda neste número após o início da pandemia da COVID-19. Assim, para a análise dos dados foi utilizado o *software R* e a abordagem de séries temporais interrompidas.



Fonte: Dos autores (2023)

As séries temporais interrompidas configuram numa abordagem não experimental utilizada para avaliar o efeito longitudinal de intervenções em variáveis de interesse (Penfold; Zhang, 2013). Então, nos estudos de STI é utilizada uma série temporal de interesse para estabelecer uma tendência subjacente, que é interrompida por uma intervenção em um ponto conhecido no tempo.

O cenário hipotético sob a ausência de tratamento é conhecido como contrafactual e considerado que a tendência não se alterou, sendo o necessário para fornecer uma comparação para a avaliação dos efeitos da intervenção. Nas análises do modelo de séries temporais interrompidas, o seguinte modelo é frequentemente utilizado:

$$Y_t = \beta_0 + \beta_1 T + \beta_2 X_t + \beta_3 T X_t \quad (1)$$

onde T é o tempo decorrido, X_t é uma variável binária (igual a zero antes da intervenção e igual a um após a intervenção), β_0 representa o intercepto ($T = 0$), β_1 é interpretado como a mudança no resultado associada a um aumento da unidade de tempo, β_2 é a mudança de nível após a intervenção e β_3 indica a mudança de inclinação após a intervenção (usando a interação entre tempo e intervenção) (Penfold; Zhang, 2013).

A estimação dos parâmetros foi feita usando o método de mínimos quadrados através do algoritmo de Gauss-Newton. A avaliação da qualidade do ajuste foi realizada com base no coeficiente de determinação. Após o ajuste, há uma curva para cada momento (antes e depois

da intervenção), que foi comparada com o contrafactual. Por fim, foram testados os pressupostos básicos da análise de resíduos, utilizando o pacote *lmtest* do *software R*.

Resultados e Discussões

Os pressupostos da análise de resíduos foram satisfeitos. O coeficiente de determinação foi acima de 99% no ajuste do modelo aos dados com o termo quadrático na variável tempo (T). Os parâmetros foram estimados para as variáveis tempo (T), variável binária que indica a intervenção (X_t) e para interação do tempo com a variável X_t . Com as estimativas obtidas, observou-se que todos os parâmetros foram significativos ao nível de 5% de significância, exceto o parâmetro associado a interação entre tempo e a variável da intervenção (Tabela 1). A partir dos resultados obtidos pelo ajuste do modelo aos dados pode-se observar que a variável X_t apresenta estimativa negativa, sugerindo que após a intervenção (neste caso, a pandemia da COVID-19) o número de beneficiários de planos de saúde reduziu em cerca de 17 mil.

Tabela 1: Ajuste do modelo de regressão linear aos dados

	Estimativa	SE	Estatística t	valor-p
Intercepto	-4148699982,0648	98166261,7904	-42,26	0,0000
T	4116034,1230	97678,4508	42,14	0,0000
T^2	-1020,8302	24,2981	-42,01	0,0000
X_t	-17190,7210	4635,5328	-3,71	0,0004
TX_t	1079,7784	577,1878	1,87	0,0647

Fonte: Dos autores (2023)

Portanto, o ajuste do modelo aos dados mostrou que não houve mudança na tendência da curva, porém ocorreu uma mudança de nível no número de beneficiários de planos de saúde. Essa alteração que ocorreu no nível da variável de interesse pode ser explicada pelo efeito da pandemia da COVID-19 na situação econômica na vida da população, bem como fatores relacionados aos óbitos pela pandemia.

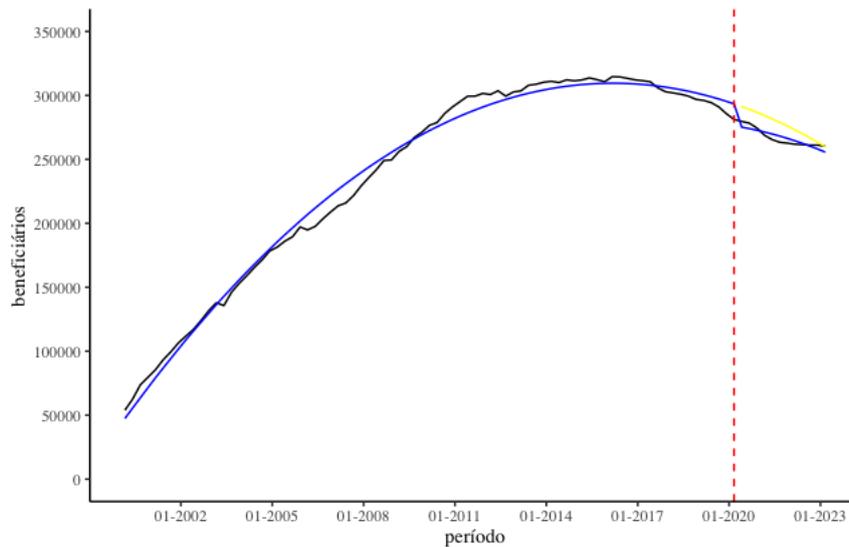
Embora a contribuição direta desses achados não seja tão óbvia quando se trata de políticas públicas, eles são fundamentais para prever o impacto das intervenções considerando estimativas preditas e contrafactuais. Tomando como exemplo a equação 1, estimaram-se valores preditos (271.365,93) e valores contrafactuais (284.237,54), verificando-se que o número de beneficiários de OPS observado em 2021 diminuiu em cerca de 13 mil contratos (Figura 2). A representação da série temporal do número de beneficiários de OPS mostra uma tendência crescente até o ano de 2014, seguido de de uma tendência decrescente para os anos seguintes, conforme indicou a Figura 2.

Além disso, pode-se observar com o ajuste do modelo que o número de beneficiários reduziu mais do que se esperava. Isso pode ser visto a partir das linhas azul (modelo ajustado) e amarela (contrafactual) na Figura 2. Logo, a redução média entre o contrafactual e o ajustado pode ser obtida pela diferença entre os segmentos em azul e amarelo após o ano de 2020 (linha tracejada), que foi de aproximadamente 10 mil beneficiários. Portanto, observou-se que a pandemia da COVID-19 impactou o mercado de saúde suplementar, em especial, os contratos de beneficiários acima de 60 anos com planos de referência da região Sudeste do Brasil.

Conclusões

Nesse sentido, o objetivo deste trabalho foi analisar os efeitos da pandemia da COVID-19 na contratação de planos de saúde na região Sudeste do Brasil para a população acima de 60 anos nos planos de referência, por meio de análise de séries interrompidas. Os dados utilizados referem-se ao número de beneficiários de planos de saúde da região sudeste do primeiro trimestre

Figura 2: Ajuste do modelo quadrático da série temporal interrompida



Fonte: Dos autores (2023)

de 2000 ao primeiro trimestre de 2023 (93 observações), oriundos da Agência Nacional de Saúde Suplementar.

A partir da análise da série temporal foi ajustado um modelo quadrático para o período anterior ao tratamento (COVID-19) e após o tratamento abordado. Com base nos ajustes destes modelos, foi possível observar que o número de beneficiários de planos de saúde na região sudeste estava reduzindo, porém a intervenção pode ter provocado uma redução mais acentuada, sendo, em média, de 10 mil beneficiários a menos que o previsto sem a intervenção.

Referências

BRASIL. *Lei no 8.080*, de 19 de setembro de 1990. Dispõe sobre as condições para a promoção, proteção e recuperação da saúde, a organização e o funcionamento dos serviços correspondentes e dá outras providências. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/18080.htm. Acesso em: 30 de Agosto de 2023.

BRASIL. *Lei no 9.656*, de 03 de junho de 1998. Dispõe sobre os planos e seguros privados de assistência à saúde. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/19656.htm. Acesso em: 16 de Junho de 2023.

BRASIL. *Lei no 9.961*, de 28 de janeiro de 2000. Cria a Agência Nacional de Saúde Suplementar – ANS e dá outras providências. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/19961.htm. Acesso em: 16 de Junho de 2023.

FIGUEIREDO, D. C. M. M. et al. Efeitos da recessão econômica na mortalidade por suicídio no Brasil: análise com séries temporais interrompidas. *Revista Brasileira de Enfermagem*, v. 75, p. e20210778, 2022.

IRVINE, M. A. et al. An interrupted time-series analysis of pediatric emergency department

visits during the coronavirus disease 2019 pandemic. *Pediatric Emergency Care*, v. 37, n. 6, p. 325-328, 2021.

NASCIMENTO, M. I. et al. Mortalidade prematura por câncer de colo uterino: estudo de séries temporais interrompidas. *Revista de Saúde Pública*, v. 54, 2020.

NUNES, H. R. C et al. Impacto da Lei Seca sobre a mortalidade no trânsito nas Unidades Federativas do Brasil: uma análise de série temporal interrompida. *Revista Brasileira de Epidemiologia*, v. 24, p. e210045, 2021.

OLIVEIRA, C. C. M. et al. Efetividade do serviço móvel de urgência (Samu): uso de séries temporais interrompidas. *Revista de Saúde Pública*, v. 53, p. 99, 2019.

PEARL, J. Causal inference. *Causality: Objectives and Assessment*, PMLR, p. 39–58, 2010.

PENFOLD, R. B.; ZHANG, F. Use of interrupted time series analysis in evaluating health care quality improvements. *Academic pediatrics*, v. 13, n. 6, p. S38-S44, 2013.

RUBIN, D. B. Estimating causal effects of treatments in randomized and nonrandomized studies. *Journal of educational Psychology*, American Psychological Association, v. 66, n. 5, p. 688, 1974.

ROSENBAUM, P. R.; RUBIN, D. B. The central role of the propensity score in observational studies for causal effects. *Biometrika*, Oxford University Press, v. 70, n. 1, p. 41–55, 1983.

VINCI, A. et al. Emergency medical services calls analysis for trend prediction during epidemic outbreaks: interrupted time series analysis on 2020–2021 COVID-19 epidemic in Lazio, Italy. *International Journal of Environmental Research and Public Health*, v. 19, n. 10, p. 5951, 2022.