

Avaliação do impacto da pandemia de COVID-19 no transporte público por ônibus no município do Rio de Janeiro

Assessment of the impact of the Covid-19 pandemic on public bus transportation in the city of Rio de Janeiro

Gabriela Maciel Wagner^{✉,1} e Lino Guimarães Marujo²

¹Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, gabriela.wagner@pet.coppe.ufrj.br, 0009-0009-0180-9841

²Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, lino.marujo@coppe.ufrj.br, 0000-0002-0355-6501

Recebido: 1 de junho de 2025

Revisão final: 28 de outubro de 2025

Aceito: 25 de maio de 2026

Publicado: 2 de setembro de 2026

Editor Associado:

Cira Souza Pitombo

Universidade de São Paulo, São Paulo, Brasil

Palavras-chave:

Transporte público por ônibus;

Pandemia de COVID-19;

Séries temporais interrompidas.

Keywords:

Public bus transportation;

COVID-19 pandemic;

Interrupted time series.

DOI: 10.58922/transportes.v34.e3135



RESUMO

A pandemia de COVID-19 provocou mudanças no comportamento de viagens decorrentes das medidas de distanciamento social. Este estudo tem como objetivo avaliar os efeitos dessas mudanças na demanda do transporte público por ônibus no município do Rio de Janeiro. Utilizando dados públicos, foram aplicadas técnicas de modelagem de séries temporais e análise exploratória. A análise da série temporal do número de passageiros transportados evidenciou uma redução de 704 milhões de passageiros em comparação com valores previstos do cenário contrafactual sem a pandemia entre março de 2020 e dezembro de 2022. Além disso, observou-se um aumento contínuo da frota de veículos individuais nos últimos anos e uma redução de 8,4% na média mensal do fluxo de veículos depois da pandemia em comparação ao período anterior. Nos primeiros meses do período pandêmico, houve maior adoção do trabalho remoto. Esses resultados destacam alguns impactos nos perfis de deslocamento decorrentes da crise sanitária.

ABSTRACT

The COVID-19 pandemic has caused changes in travel behavior due to social distancing measures. This study aims to assess the effects of these changes on the demand for public bus transportation in the city of Rio de Janeiro. Using public data, time series modeling techniques and exploratory analysis were applied. The analysis of the time series of the number of passengers transported revealed a reduction of 704 million passengers compared to the projected values from the counterfactual scenario without the pandemic between March 2020 and December 2022. Additionally, there has been a continuous increase in the fleet of individual vehicles over the past years and an 8.4% reduction in the average monthly vehicle flow after the pandemic compared to the previous period. During the early pandemic months, there was a greater adoption of remote work. These findings highlight some impacts on travel patterns resulting from the health crisis.

1. Introdução

Em dezembro de 2019, um novo vírus foi identificado na cidade de Wuhan, província de Hubei, na República Popular da China, sendo posteriormente nomeado SARS-CoV-2 (Vos, 2020). No município do Rio de Janeiro, o primeiro caso confirmado do novo coronavírus foi registrado no início de março de 2020 (Cavalcante & Abreu, 2020). No mesmo mês, a Organização Mundial da Saúde (doravante OMS) declarou a COVID-19 como uma pandemia (Vos, 2020). Em resposta ao surto, a OMS defendeu o distanciamento social como o principal método para a redução da velocidade de transmissão do vírus e para evitar a sobrecarga nos serviços de saúde, destacou a recomendação do Conselho Nacional de Saúde (2020).

A pandemia de COVID-19 afetou o comportamento de viagens em todo o mundo, levando a uma redução na circulação de pessoas e na utilização do transporte público devido ao risco de transmissão do vírus por meio do contato próximo com uma pessoa infectada (Abdullah *et al.*, 2021). As medidas de distanciamento social implementadas por diversos países para conter a propagação do vírus impactaram significativamente os sistemas de transporte. Essas medidas resultaram na necessidade de realizar muitas atividades de forma remota, gerando consequências de curto e longo prazo no setor de transportes (Silva *et al.*, 2022).

Alguns indicadores apresentados no relatório anual da Associação Nacional das Empresas de Transportes Urbanos - NTU (2021) evidenciam os reflexos negativos da pandemia no transporte público por ônibus. Verificou-se uma redução de 51,1% das viagens realizadas por passageiros pagantes no ano de 2020 em relação a 2019. Além disso, o índice de passageiros equivalentes transportados por quilômetro foi igual a 1 no ano de 2020, indicando que apenas um passageiro foi transportado por quilômetro percorrido. O relatório também ressalta que a significativa redução da demanda do transporte público por ônibus desde março de 2020 soma-se à tendência expressiva de queda das últimas décadas.

Pesquisas ao redor do mundo buscaram identificar e compreender as alterações nos perfis de deslocamento decorrentes da pandemia, comparando-as com os padrões anteriores a este momento e também investigando possíveis mudanças permanentes. Alguns desses estudos são de Shakibaei *et al.* (2021), na Turquia; Abdullah *et al.* (2021), no Paquistão; Yang *et al.* (2021), na China; e, no Brasil, Costa, Pitombo & Souza (2022) e Freitas *et al.* (2020). Contudo, apesar dos diversos estudos realizados com essa finalidade, poucos utilizaram dados públicos e conduziram análises estatísticas para investigar a relação entre esses dados e mensurar os impactos.

Nesse contexto, o objetivo deste trabalho consiste em avaliar as mudanças no comportamento de viagens resultantes das medidas de distanciamento social implementadas durante a pandemia de COVID-19, concentrando-se nos efeitos sobre a demanda do transporte público por ônibus no município do Rio de Janeiro. A pesquisa se fundamentou na coleta e análise das seguintes bases de dados públicas disponíveis online: número de passageiros transportados, fluxo de tráfego, frota de veículos e PNAD COVID-19, possibilitando a investigação dos impactos associados ao uso do transporte público por meio da modelagem de séries temporais e análise exploratória.

2. Referencial teórico

2.1. Comportamento de viagens durante a pandemia de COVID-19

Em todo o mundo, o setor de transportes foi um dos mais afetados pela pandemia de COVID-19 (Silva *et al.*, 2022). As medidas adotadas para controlar a disseminação do vírus estão intimamente relacionadas à mobilidade urbana e, juntamente com a percepção da gravidade da doença, ocasionaram mudanças nos padrões de mobilidade por todo o mundo (Costa, Pitombo & Souza, 2022). Estudos realizados em diversos países procuraram compreender as alterações que ocorreram nos padrões de viagem e a possibilidade dessas mudanças permanecerem após a crise sanitária.

As pesquisas conduzidas por Shakibaei *et al.* (2021) em Istambul, Turquia, Abdullah *et al.* (2021) no Paquistão e Yang *et al.* (2021) em Huzhou, China, evidenciaram mudanças nos padrões de viagens decorrentes da pandemia. Em Istambul, observou-se um aumento no uso de carros particulares em detrimento do transporte público, enquanto o teletrabalho e a educação a distância se destacaram como alternativas. No Paquistão, as viagens relacionadas a trabalho e educação diminuíram, enquanto as viagens de compras e a preferência pelo uso de carro próprio em deslocamentos longos aumentaram. Na China, as pessoas evitaram o transporte público, optando por carros particulares, além do aumento da preferência por bicicletas e caminhadas para deslocamentos de curta distância.

No Brasil, Costa, Pitombo & Souza (2022) realizaram uma pesquisa visando analisar os perfis de deslocamento antes e durante a pandemia em vários estados do país. Os autores constataram que os modos de transporte mais utilizados antes da pandemia eram o carro, o transporte público por ônibus e o ridesourcing, representando 34,7%, 25,4% e 11,7% respectivamente. Durante a pandemia, ocorreram mudanças significativas na utilização desses meios de transporte, com um aumento para 43,6% no uso de carros e para 13,9% no de ridesourcing e uma queda para 12,6% na utilização do transporte público por ônibus. O estudo verificou que houve aumento na utilização de automóveis para deslocamentos até o trabalho, contudo ocorreu uma redução no número de viagens para o trabalho devido ao crescimento do teletrabalho com as medidas de distanciamento.

Na Região Metropolitana do Rio de Janeiro, um estudo com o propósito de investigar os padrões de viagem para o trabalho antes e durante a crise sanitária foi conduzido por Freitas *et al.* (2020). Os resultados da pesquisa mostraram que a maioria dos respondentes utilizava carro, ônibus ou a




Figura 1 • Exemplos de efeitos de uma intervenção em séries temporais, adaptado de Bernal, Cummins & Gasparrini (2017).

combinação de dois modos de transporte para o deslocamento até o trabalho antes da pandemia. Após o início do surto, verificou-se que a maioria das pessoas deixou de ir ao local de trabalho e, entre aquelas que ainda precisavam se deslocar, o automóvel se tornou o meio de transporte predominante.

2.2. Análise de séries temporais interrompidas

O objetivo da análise de séries temporais interrompidas é avaliar o impacto de uma intervenção no comportamento da série (Morettin & Toloi, 2006). Uma intervenção é o acontecimento de algum tipo de evento em um determinado instante de tempo, por exemplo, introdução de uma nova lei, implementação de políticas públicas, mudanças climáticas, desastres ambientais, pandemias. Uma intervenção pode impactar uma série temporal de vários modos, alterando o nível ou a inclinação da série. Esse efeito pode se manifestar de forma abrupta ou gradual após a intervenção e em relação à duração pode ser temporário ou permanente (Bernal, Cummins & Gasparrini, 2017).

A Figura 1 ilustra alguns efeitos de intervenção sobre uma série temporal.

Na Figura 1, observam-se diferentes efeitos: (a) mudança de nível imediata e permanente, (b) mudança imediata na tendência com duração permanente (c) mudança de nível imediata seguida de alteração gradual de tendência, ambas permanentes, (d) mudança de tendência manifestada um período de tempo após a intervenção de maneira gradual, (e) mudança de nível imediata com duração temporária, e (f) mudança temporária de tendência e uma mudança permanente de nível.

De acordo com Schaffer, Dobbins & Pearson (2021), três efeitos principais podem ser observados após uma intervenção: mudança de nível, impulso e rampa. Considerando T_0 o instante inicial que ocorreu a intervenção, esses efeitos podem ser representados da seguinte forma:

- a) **Mudança de nível:** mudança abrupta e permanente, na qual a série temporal é deslocada para cima ou para baixo após a intervenção. A variável de mudança de nível assume o valor 0 antes do início da intervenção e 1 depois da intervenção.
- b) **Impulso:** mudança abrupta e temporária observada em um ou mais pontos após a intervenção e depois retorna ao mesmo nível de antes da intervenção. A variável impulso assume o valor 1 no instante da intervenção e 0 nos outros pontos.
- c) **Rampa:** mudança abrupta na inclinação da série temporal após a intervenção. A variável recebe valor 0 antes da intervenção e aumenta em 1 após o momento da intervenção.

2.3. Modelo ARIMA

A ocorrência de um desfecho específico em meses consecutivos não pode ser tratada como observações independentes, pois o resultado de um mês pode influenciar o do mês seguinte, e essa correlação pode se manifestar em intervalos anuais, especialmente em eventos sazonais (Rodrigues, 2022). Lucambio Pérez (2022) complementa afirmando que em séries temporais é necessário considerar que a variável resposta pode ser influenciada pelos valores passados das variáveis preditoras, assim como por seus próprios valores anteriores. Modelos regressivos estimam o valor de uma variável dependente a partir de uma combinação linear das variáveis independentes, enquanto modelos autorregressivos utilizam uma combinação linear dos valores passados da própria variável (Hyndman & Khandakar, 2008).

Além disso, uma das suposições a respeito de uma série temporal é a de que ela é estacionária, contudo a maioria das séries possui alguma forma de não estacionariedade, como tendência e sazonalidade (Morettin & Toloi, 2006). Os modelos ARIMA conseguem descrever tanto séries estacionárias quanto não estacionárias.

Um modelo autorregressivo (AR) é descrito matematicamente como mostra a Equação 1, na qual y_t é estimada por um ou múltiplos valores passados de y_t , c é uma constante, ϕ é a magnitude da autocorrelação, p é o número de defasagens e ε_t é o erro (Hyndman & Khandakar, 2008):

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t. \quad (1)$$

Um modelo de médias móveis (MA) usa erros de previsão passados para estimar y_t . Sua representação matemática está disposta na Equação 2, na qual y_t é estimado por um ou vários valores passados do ε_t , θ é o valor de autocorrelação dos erros e q é o número de defasagens:

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}. \quad (2)$$

A estacionariedade de uma série temporal é um dos requisitos para a aplicação do modelo ARIMA. Caso a série não seja estacionária, ela pode ser transformada através de um processo conhecido como diferenciação. A diferenciação consiste na diferença entre o valor de uma observação pelo valor da observação anterior, como demonstrado na Equação 3:

$$y'_t = y_t - y_{t-1}. \quad (3)$$

O modelo ARIMA é a combinação da diferenciação, com o modelo autorregressivo e o modelo de média móvel. O nome do modelo deriva do inglês *autoregressive integrated moving average*. O modelo pode ser escrito matematicamente como apresentado na Equação 4, na qual y'_t corresponde à série diferenciada (Hyndman & Khandakar, 2008):

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t. \quad (4)$$

O modelo ARIMA é representado pela notação $ARIMA(p, d, q)$, composto por três parâmetros, no qual p é a ordem da parte autorregressiva, d é o grau de diferenciação e q é a ordem da parte de média móvel. Para séries que apresentam sazonalidade, utiliza-se o modelo SARIMA, representado pela notação $SARIMA(p, d, q)(P, D, Q)_s$, no qual é acrescido os parâmetros da parte sazonal e s corresponde ao número de períodos da sazonalidade.

O método de Box & Jenkins utilizado para a construção desses modelos é composto por três etapas: identificação do modelo, estimação dos parâmetros e verificação do modelo ajustado (Morettin & Toloi, 2006).

2.4. Aplicações de análise de séries temporais interrompidas

A análise de séries temporais interrompidas é uma abordagem aplicada em diversas áreas, incluindo economia, ciências sociais, ciência política, saúde, meio ambiente e transporte. Nesse contexto, diferentes pesquisas buscaram avaliar o efeito de uma intervenção em sistemas de transporte.

Um estudo conduzido por [Fuller et al. \(2012\)](#) avaliou os efeitos de duas greves no metrô de Londres sobre a utilização de um programa público de compartilhamento de bicicletas. Os autores empregaram o modelo de regressão segmentada para analisar o impacto das greves no número diário de viagens e na duração média das viagens por dia. A média do número de viagens diárias ao longo do estudo foi de 14.699. Após a primeira greve, houve um aumento imediato de 3.864 viagens, contudo esse aumento inicial foi seguido por uma redução significativa, retornando aos níveis pré-greves. O mesmo ocorreu na segunda greve, um aumento imediato de 11.263 viagens, seguido de uma redução para os valores vistos no período anterior às greves. Em relação à duração média das viagens, que era de 18,5 minutos, observou-se uma diminuição significativa de 0,20 minutos por dia no período pré-greve. Contudo, as greves não tiveram um efeito significativo na duração das viagens.

[Borgatto \(2000\)](#) analisou o comportamento do transporte urbano na cidade de São Paulo utilizando a análise de séries temporais interrompidas. As séries analisadas foram número médio de passageiros por dia entre 1983 e 1998, número de assaltos nos ônibus urbanos entre 1992 e 1999 e número de acidentes de trânsito com os ônibus urbanos entre 1988 e 1999. Empregando a metodologia de Box e Jenkins, o autor analisou o efeito de diversas intervenções, como a privatização da Companhia Municipal de Transportes Coletivos (CMTC) em janeiro de 1993 e eventos extraordinários que ocasionaram acréscimos ou decréscimos nas séries analisadas. Na série do número médio de passageiros, observou-se o impacto significativo do incentivo ao uso do transporte público e do aumento do número de ônibus. Na série do número de acidentes, constatou-se um aumento do número de acidentes no período da privatização da CMTC. Por fim, na série do número de assaltos, identificou-se um aumento significativo em dois momentos, contudo não foi possível identificar os acontecimentos que interferiram nessa série.

3. Metodologia

3.1. Local do estudo

O município do Rio de Janeiro é a segunda maior metrópole brasileira, com uma população estimada em 6.775.561 habitantes em 2021, de acordo com o Instituto Brasileiro de Geografia e Estatística ([IBGE, 2023](#)). O sistema de transporte público da cidade é composto por ônibus, metrô, trem e barcas. Entre esses modos, o ônibus é o mais utilizado pela população carioca, registrando uma média diária de aproximadamente 3,1 milhões de passageiros transportados ao longo dos anos de 2010 a 2019, conforme dados fornecidos pelo [Data.Rio \(2023\)](#).

3.2. Coleta dos dados

A coleta dos dados consistiu na obtenção de informações relacionadas à operação de ônibus no município e de dados relacionados ao volume de tráfego, frota de veículos e mercado de trabalho. Essa primeira informação foi obtida através do acesso ao site da Secretaria Municipal de Transporte do Rio de Janeiro (doravante SMTR). A quantidade de passageiros transportados foi obtida por meio dos painéis interativos disponíveis no site, abrangendo o período de janeiro de 2015 a dezembro de 2022 ([SMTR, 2022a](#)).

A Companhia de Engenharia de Tráfego do Rio de Janeiro (doravante CET-Rio) disponibiliza relatórios com os dados de fluxo de tráfego no município do Rio de Janeiro ([CET-Rio, 2022](#)). Esses relatórios apresentam o Indicador Global de Volume Veicular (IGVOL) referente ao período de novembro de 2015 a dezembro de 2022. O IGVOL é obtido a partir da média mensal de tráfego dos principais pontos de corredores estruturais e arteriais, seguindo a classificação viária adotada pela CET-Rio. No portal do DETRAN-RJ, foram coletados os dados referentes à frota de automóveis e motocicletas na cidade entre janeiro de 2015 e dezembro de 2022 ([DETRAN-RJ, 2022](#)).

As informações referentes ao impacto da pandemia no mercado de trabalho foram obtidas por meio dos resultados da Pesquisa Nacional por Amostra de Domicílios - PNAD COVID-19 ([IBGE, 2020](#)). Essa pesquisa aborda questões como o afastamento do trabalho e a prática do trabalho remoto devido ao distanciamento social na pandemia.

3.3. Ferramentas de análise dos dados

A análise dos dados foi conduzida empregando-se duas abordagens metodológicas. A análise de séries temporais interrompidas foi aplicada para o número de passageiros transportados, incluindo pagantes e gratuidades, enquanto para os demais dados realizou-se uma análise exploratória.

A série temporal referente à quantidade de passageiros transportados compreende 96 meses, de janeiro de 2015 a dezembro de 2022. Foram definidos dois períodos para a modelagem: o pré-pandemia, com 62 observações entre janeiro de 2015 e fevereiro de 2020, e o pós-pandemia, com 34 observações entre março de 2020 e dezembro de 2022. O mês de março de 2020 foi estabelecido como o instante da intervenção em razão da implementação das medidas de distanciamento social no município.

A análise de séries temporais interrompidas utilizando o modelo ARIMA seguiu quatro etapas, conforme proposto por [Schaffer, Dobbins & Pearson \(2021\)](#). A primeira consistiu na representação gráfica da série, visando a identificar padrões, como tendência, sazonalidade e observações atípicas. Para isso, utilizou-se o gráfico de decomposição da série temporal.

Na segunda etapa, verificou-se a estacionariedade da série por meio do teste de Dickey-Fuller Aumentado, aplicando-se diferenciação quando necessário para estabilizar a variância. A terceira etapa envolveu a seleção do modelo. A identificação dos parâmetros foi realizada de forma automatizada pela função `auto.arima`, disponível no pacote `forecast` da linguagem R, desenvolvido por [Hyndman & Khandakar \(2008\)](#). Nessa fase, também foi avaliado o efeito da intervenção, incorporando variáveis exógenas, “nível” e “rampa”, ao modelo. A variável “nível” representa a mudança de nível da série, assumindo o valor 0 para os meses anteriores à intervenção e valor 1 para os meses posteriores. A variável “rampa” representa a mudança de inclinação da série após a intervenção, recebendo valores sequenciais a partir de 1 no início da intervenção e valor 0 para os meses anteriores.

A quarta etapa consistiu na verificação do modelo, avaliando se os resíduos se comportam como ruído branco, ou seja, não apresentam autocorrelação. Além da análise gráfica, aplicou-se o teste de Ljung-Box, no qual a hipótese nula indica ausência de autocorrelação nos resíduos ([Pereira et al., 2021](#)). Concluída a seleção do modelo, foi possível estimar o impacto da pandemia sobre a série, construindo-se o cenário contrafactual, isto é, a previsão de como seria o comportamento da série na ausência da intervenção. Todas as etapas foram realizadas com auxílio do Google Collaboratory utilizando a linguagem R.

A análise dos dados referentes ao fluxo de tráfego, frota de veículos e trabalho remoto envolveu a aplicação de técnicas estatísticas descritivas e a criação de representações gráficas. Essas abordagens foram utilizadas com o intuito de compreender o comportamento geral dos dados, identificar possíveis valores discrepantes, descrever as principais características dessas variáveis e investigar as relações entre elas.

4. Resultados e discussão

4.1. Passageiros transportados no sistema de transporte público por ônibus

A série temporal da quantidade de passageiros transportados abrangendo os meses de janeiro de 2015 a dezembro de 2022 é apresentada na Figura 2(a). Observa-se que o transporte público por ônibus tem enfrentado uma diminuição na demanda nos últimos anos. Comparando-se o número de passageiros transportados em janeiro de 2015 com dezembro de 2019, verifica-se uma redução de 23,9%, o que corresponde a 18.922.031 usuários. Além disso, ocorreu uma queda acentuada na demanda a partir de março de 2020, associada ao surgimento da crise sanitária. Em abril do mesmo ano, foi registrada uma queda abrupta de mais de 57% no número de passageiros em relação ao mês anterior, equivalente a 32.790.856 usuários, atribuída às medidas de restrição de circulação de pessoas implementadas com o objetivo de conter a disseminação do vírus. No ano de 2020, a demanda apresentou uma redução de 45,2% em comparação ao ano de 2019, percentual que corresponde a 455.893.673 passageiros. Na Figura 2(b) são ilustrados os marcos temporais referentes às medidas restritivas de acordo com os decretos municipais relacionados ao enfrentamento da COVID-19, obtidos através do portal da Prefeitura do Rio de Janeiro.




Figura 2 • Série temporal do número de passageiros transportados (a) entre 2015 e 2022 e (b) entre 2020 e 2022.

Tabela 1 • Resultados do Teste de Dickey-Fuller Aumentado.

Transformação	Dickey-Fuller Aumentado	valor-p	1%	5%	10%
Nenhuma	-1,0526	0,7336	-3,5117	-2,8970	-2,5857
Diferenciação	-2,3617	0,1529	-3,5117	-2,8970	-2,5857
Diferenciação + diferenciação sazonal	-8,8097	0,0000	-3,5127	-2,8975	-2,5859

No período pré-pandemia, a média mensal de passageiros transportados foi de aproximadamente 97 milhões, enquanto no período pós-pandemia essa média diminuiu para cerca de 50 milhões de passageiros. A Figura 3 apresenta a decomposição da série temporal, destacando os componentes de tendência, sazonalidade e resíduos. Ao analisar a decomposição da série temporal, é notável uma tendência decrescente no número de passageiros durante o período pré-pandemia, indicada pela inclinação negativa da reta. Com o surgimento da pandemia, houve uma queda acentuada na demanda de passageiros nos primeiros meses, refletindo as restrições de mobilidade impostas. No entanto, à medida que as restrições foram sendo flexibilizadas, ocorreu um aumento gradual de usuários com o retorno das atividades das indústrias, comércios e serviços, resultando em uma nova tendência ascendente na demanda. Acrescenta-se a isso, a presença de sazonalidade na série temporal, com os meses de janeiro e fevereiro apresentando menor demanda. Este comportamento pode estar associado ao período de férias escolares, quando há uma diminuição na movimentação de passageiros.

Para avaliar a estacionariedade da série, foi utilizado o teste estatístico de Dickey-Fuller Aumentado. Nesse teste é analisado se a série temporal possui uma raiz unitária, o que indica que a série não é estacionária (hipótese nula), ou se não há raiz unitária, indicando que a série é estacionária (hipótese alternativa). Os resultados do teste, apresentados na Tabela 1, indicam que a série, sem aplicar nenhuma diferenciação, não é estacionária, conforme evidenciado pelo valor-p superior ao nível de significância de 5%.

No comportamento da série, é possível observar a tendência decrescente antes da pandemia e a presença de sazonalidade, como podem ser vistos na Figura 4(a), referente à série sem diferenciação. Sendo assim, aplicou-se a diferenciação à série para torná-la estacionária. Foram necessárias duas diferenciações para obter a estacionariedade da série, a primeira de ordem regular e a segunda de ordem sazonal. Em seguida, o teste de Dickey-Fuller Aumentado foi novamente aplicado para avaliar a estacionariedade da série já diferenciada. Os resultados do teste após a primeira diferenciação e após a diferenciação sazonal são apresentados na Tabela 1. A série, após a aplicação dessas diferenciações, foi representada na Figura 4(b). Com base nesses resultados, definiu-se a ordem d e D igual a 1.

A seleção do modelo foi realizada de forma automatizada por meio da função `auto.arima`, que indica o modelo mais adequado com base na minimização dos critérios de informação Akaike Information




Figura 3 • Decomposição da série temporal do número de passageiros transportados.





Figura 4 • Série temporal do número de passageiros transportados (a) não estacionária e (b) estacionária.

Criteria (AIC) e Bayesian Information Criteria (BIC) (Schaffer, Dobbins & Pearson, 2021). Contudo, é importante mencionar que a minimização do AIC pode resultar em uma diferenciação excessiva da série, o que deve ser evitado para fins de previsão, pois pode prejudicar as previsões e ampliar os intervalos de previsão Hyndman & Khandakar (2008). Por essa razão, a função `auto.arima` foi configurada com um valor máximo de d e D igual a 1. Essa escolha foi baseada na constatação anterior da estacionaridade da série com duas diferenciações, sendo a segunda uma diferenciação sazonal.

O modelo $SARIMA(0, 1, 1)(2, 0, 0)_{12}$ foi selecionado como o melhor pelo algoritmo. Resumidamente, esse modelo é composto por uma diferenciação de ordem 1, um termo de média móvel de ordem 1 e um componente sazonal com autocorrelação de ordem 2. Os resultados do modelo estão dispostos na Tabela 2, na qual são fornecidos os coeficientes, erros padrão, valores- p e intervalos de confiança (IC) para cada parâmetro estimado. Todos os parâmetros foram considerados estatisticamente significativos, visto que apresentam valores- p inferiores a 0,05. Os critérios de informação do modelo selecionado apresentaram

Tabela 2 • Resultado dos parâmetros do modelo SARIMA(0, 1, 1)(2, 0, 0)₁₂.

Parâmetro	Coefficiente	Erro padrão	valor-p	IC 95%
MA	-0,7490	0,0890	0,0000	[-0,92; -0,57]
SAR1	0,3419	0,0937	0,0003	[0,16; 0,52]
SAR2	0,3541	0,0982	0,0003	[0,16; 0,55]

**Figura 5** • Resíduos do modelo SARIMA(0,1,1)(2,0,0)₁₂ para o número de passageiros transportados.

valores de 599,94 para o AIC e 615,29 para o BIC.

A última etapa do método Box & Jenkins consiste na verificação do modelo ajustado. Com isso, o teste de Ljung-Box foi realizado para avaliar o ajuste do modelo, verificando se os resíduos do modelo são independentes e não apresentam autocorrelação significativa. O valor- p obtido foi igual a 0,88 para 24 defasagens, levando à aceitação da hipótese nula do teste. Esse resultado indica a ausência de autocorrelação significativa nos resíduos, o que sugere que o modelo apresenta um bom ajuste.

Os resíduos do modelo são ilustrados graficamente na Figura 5. A análise evidencia a adequação do modelo SARIMA(0,1,1)(2,0,0)₁₂ para representar a série temporal do número de passageiros transportados. Na Figura 5(a), que exibe os resíduos em ordem temporal, observa-se que os resíduos estão distribuídos aleatoriamente em torno de zero, indicando que são independentes entre si. O gráfico da função de autocorrelação (ACF) na Figura 5(b) revela que os resíduos se mantêm dentro dos limites esperados, não apresentando correlação significativa. Por fim, o histograma na Figura 5(c) indica que os resíduos seguem uma distribuição aproximadamente normal.

Após a confirmação da adequação do modelo, foram realizadas previsões para avaliar os impactos da pandemia na demanda do transporte público por ônibus. Dessa forma, estimou-se o número de passageiros transportados considerando um cenário hipotético no qual a pandemia não tivesse ocorrido, denominado cenário contrafactual. Os valores previstos, juntamente com os valores observados, são apresentados na Figura 6. Observa-se uma mudança de nível na série, com uma redução estimada de 20,8 milhões de passageiros em março de 2020.

Foi calculada a diferença entre os valores observados e previstos no período pós-pandemia, assim como a variação percentual entre esses valores, conforme apresentado na Tabela 3. Os maiores desvios absolutos e percentuais ocorreram em maio e abril de 2020, com diferenças de -54,1 e -52,1 milhões




Figura 6 • Valores observados e valores previstos na ausência da pandemia com base no modelo SARIMA(0,1,1)(2,0,0)12.

de passageiros, respectivamente. Por outro lado, dezembro de 2022 apresentou a menor diferença e variação percentual, com uma diferença de $-3,8$ milhões de passageiros e uma variação percentual de $-6,1\%$. Esse resultado indica uma aproximação entre o número de passageiros transportados e a demanda prevista se não houvesse ocorrido a pandemia, considerando a tendência de redução no uso do transporte público por ônibus ao longo dos últimos anos. A perda de usuários pode estar associada a mudanças no perfil de deslocamento, como a preferência pelo uso do veículo individual.

No período compreendido entre março de 2020 e dezembro de 2022, foi constatada uma perda substancial no volume de passageiros, totalizando aproximadamente 704 milhões de usuários (Tabela 3). Essa redução da demanda, somada às quedas registradas nos anos anteriores, levanta preocupações quanto à continuidade da prestação do serviço, uma vez que o sistema de transporte público por ônibus é financiado em sua maioria pelas tarifas pagas pelos passageiros.

Nesse cenário, em maio de 2022, foi firmado um acordo judicial entre a Prefeitura da cidade do Rio de Janeiro, os consórcios de ônibus do município e o Ministério Público Estadual. O acordo estabeleceu a manutenção do valor da tarifa vigente na época, mediante o pagamento de subsídios às empresas de ônibus, e entrou em vigor a partir de junho de 2022 (SMTR, 2022b). Durante o período de junho a dezembro de 2022, foram alocados recursos no valor total de R\$ 232.860.345 como subsídios às empresas (SMTR, 2022b).


4.2. Volume de tráfego e frota de veículos individuais

A Figura 7 ilustra a evolução mensal do indicador de fluxo de tráfego, IGVOL, no período de janeiro de 2016 a dezembro de 2022. Durante o período pré-pandemia, o indicador registrava uma média mensal de 1,63 milhão. Com o início das restrições de circulação em março de 2020, houve uma queda no volume veicular, seguida por uma redução acentuada em abril, atingindo o nível mais baixo dos últimos anos. Essa redução em abril representou uma contração de 43% no volume veicular em comparação com a média mensal do período pré-pandemia. Nos meses seguintes, o indicador IGVOL apresentou um aumento gradual, aproximando-se da média dos anos anteriores. Entretanto, em nenhum mês o indicador alcançou a média observada na fase anterior à crise sanitária.

Diante desse cenário, evidencia-se que os indivíduos têm optado por alternativas ao transporte público coletivo, uma vez que se nota a retomada do volume de tráfego em níveis próximos aos observados anteriormente, enquanto a demanda por ônibus não apresenta a mesma recuperação. Esses resultados sugerem que, diante das medidas de isolamento e distanciamento social impostas pela COVID-19, as pessoas estão dando preferência aos meios de transporte individuais. Essa preferência pode ser confirmada pela redução de apenas 9,8% na média mensal do fluxo de veículos, de 1,63 milhão no período pré-pandemia para 1,47 milhão no período pós-pandemia. Em contrapartida, a média mensal de passageiros transportados no período pós-pandemia apresentou uma redução de 48,9% em relação ao período anterior à pandemia, equivalente a aproximadamente 47,4 milhões de usuários a menos.

Tabela 3 • Valores observados, previstos, diferença e variação percentual (março/2020 a dezembro/2022).

Mês/Ano	Obs. (A)	Prev. (B)	Dif. (A-B)	Var %
mar/2020	56,84	77,64	-20,80	-26,79%
abr/2020	24,05	76,11	-52,06	-68,40%
mai/2020	25,60	79,74	-54,14	-67,89%
jun/2020	31,28	75,06	-43,78	-58,33%
jul/2020	40,28	76,46	-36,17	-47,31%
ago/2020	43,49	81,52	-38,03	-46,65%
set/2020	43,05	77,27	-32,21	-41,69%
out/2020	47,84	81,24	-33,40	-41,12%
nov/2020	47,14	74,15	-27,01	-36,42%
dez/2020	47,93	72,65	-24,72	-34,02%
jan/2021	45,65	68,33	-22,67	-33,18%
fev/2021	42,81	65,60	-22,79	-34,74%
mar/2021	47,15	70,04	-22,89	-32,68%
abr/2021	42,56	69,91	-27,35	-39,13%
mai/2021	46,73	73,82	-27,09	-36,70%
jun/2021	48,29	68,90	-20,61	-29,91%
jul/2021	51,79	70,67	-18,88	-26,72%
ago/2021	53,16	74,49	-21,33	-28,63%
set/2021	52,75	71,37	-18,62	-26,09%
out/2021	54,94	74,83	-19,88	-26,57%
nov/2021	55,73	68,30	-12,57	-18,41%
dez/2021	56,68	66,77	-10,09	-15,11%
jan/2022	47,53	62,70	-15,17	-24,20%
fev/2022	50,32	59,84	-9,52	-15,90%
mar/2022	56,77	64,90	-8,14	-12,54%
abr/2022	52,91	64,34	-11,43	-17,77%
mai/2022	60,40	67,59	-7,18	-10,63%
jun/2022	56,87	63,47	-6,60	-10,39%
jul/2022	56,65	64,85	-8,20	-12,65%
ago/2022	61,80	68,52	-6,72	-9,80%
set/2022	59,40	65,49	-6,10	-9,31%
out/2022	58,96	68,61	-9,65	-14,07%
nov/2022	58,11	62,85	-4,75	-7,55%
dez/2022	57,80	61,55	-3,75	-6,09%

**Figura 7 •** Indicador Global do Volume Veicular.




Figura 8 • Variação mensal da frota de automóveis e motocicletas.

A frota de automóveis e motocicletas continuou em crescimento entre 2020 e 2022, conforme ilustrado na Figura 8, na qual apresenta as taxas de crescimento mensal da frota de veículos nesse período. Observa-se que o aumento da frota de motos foi superior ao de carros, enquanto a primeira registrou um crescimento de 14,64% entre 2019 e 2022, a segunda cresceu apenas 2,10%. O menor incremento foi registrado em abril de 2020, possivelmente associado à redução da circulação de pessoas no início da pandemia. Por outro lado, o maior crescimento foi observado em janeiro de 2021, com um acréscimo de 0,29% na frota total de automóveis e motocicletas.

Esse aumento contínuo da frota pode ser explicado pela predileção das pessoas pelo transporte motorizado individual, possivelmente influenciada pela qualidade do transporte público por ônibus. Os dados disponibilizados pela [SMTR \(2022a\)](#) indicam uma redução no número de viagens ofertadas pelo sistema de transporte público por ônibus no município nos últimos anos, sugerindo uma possível deterioração na qualidade e competitividade dos serviços prestados, resultando potencialmente na perda de mais usuários do sistema. Além disso, essa predileção pelo uso de veículos individuais acarreta consequências significativas, não apenas pela redução da demanda do transporte público coletivo, mas também pelo aumento de congestionamentos, poluição atmosférica, visual e sonora, consumo intensivo de energia e ocupação intensa do espaço urbano.

4.3. Trabalho remoto

O trabalho remoto foi adotado como uma estratégia para controlar a disseminação do vírus e permitir a continuidade das atividades econômicas ([Benavides et al., 2021](#)). A pesquisa PNAD COVID-19, realizada entre maio e novembro de 2020, forneceu estimativas sobre a adesão ao teletrabalho no município. A Figura 9 apresenta a porcentagem de entrevistados que adotaram o trabalho remoto. Nos meses de maio e junho, observou-se a maior proporção de pessoas nessa condição, representando 37% e 35,5%, respectivamente, do total de pessoas ocupadas e não afastadas. Nesses mesmos meses, o indicador




Figura 9 • Porcentagem de pessoas em trabalho remoto entre maio de 2020 e novembro de 2020.

IGVOL registrou um dos valores mais baixos durante o período pandêmico, reforçando a evidência da redução de movimentação das pessoas.

Nos meses seguintes, com a flexibilização das medidas restritivas e a gradual retomada das atividades econômicas, a proporção de pessoas trabalhando remotamente diminuiu. No último mês da pesquisa, novembro de 2020, constatou-se que 23,7% das pessoas estavam atuando de forma remota. No mesmo período, houve um aumento do volume de veículos, sugerindo que aqueles que retomaram às atividades presenciais possivelmente optaram pelo uso de transporte individual, considerando que a demanda do transporte público apresentava-se significativamente abaixo dos valores esperados.

A PNAD COVID-19 é a única pesquisa nacional que desempenhou um papel fundamental no acompanhamento do trabalho remoto no país e o seu encerramento impõe desafios para análises futuras que visam compreender se as mudanças observadas durante a pandemia são de natureza transitória ou permanente (Góes, Martins & Nascimento, 2021).

5. Considerações finais

Durante o desenvolvimento deste estudo, observaram-se os efeitos provocados pela pandemia de COVID-19 na mobilidade urbana do município do Rio de Janeiro. Nesta pesquisa, foram avaliados os impactos no sistema de transporte público por ônibus por meio da análise de séries temporais interrompidas. Através do modelo selecionado SARIMA(0,1,1)(2,0,0)₁₂, foi mensurado os impactos sofridos por esse meio de transporte.

Com base nos resultados encontrados, verificou-se uma redução de 29,5% no número de usuários do sistema de transporte público por ônibus entre março de 2020 e dezembro de 2022, em comparação à demanda estimada no cenário contrafactual, que representa a situação hipotética na qual a pandemia não ocorreu. Além dessa redução substancial, também foi observada uma tendência de queda na demanda ao longo dos últimos anos. A diferença entre os valores observados e previstos da demanda evidencia a esperada diminuição de passageiros nos ônibus, sendo o mês de dezembro de 2022 o mês que apresentou a menor variação percentual entre esses valores.

Essa mudança no perfil de deslocamento não está apenas associada às adaptações necessárias para conter a disseminação do vírus, mas também pode ser atribuída à crescente preferência pelo transporte motorizado individual, como carros e motocicletas, evidenciada pelo crescimento da frota desses veículos nos últimos anos. Além disso, foi observado que o volume de veículos nas principais vias da cidade sofreu uma significativa contração em de abril de 2020, e nos meses subsequentes, o fluxo de tráfego aumentou gradativamente.

Adicionalmente, a adoção do teletrabalho pode ter contribuído potencialmente para a redução do uso do transporte coletivo e do fluxo de veículos. Contudo, devido à limitação dos dados disponíveis

relacionados a esse regime de trabalho no município, não foi possível realizar uma análise dessa variável no mesmo período em que as outras variáveis foram analisadas. Outros fatores também podem ter influenciado a movimentação de pessoas na cidade, como o arrefecimento da economia, resultando na redução de empregos, bem como o aumento de compras online. Além disso, o uso de serviços de ridesourcing e a mobilidade ativa, como o uso de bicicletas e caminhadas, podem ter afetado os perfis de deslocamento. Sugerem-se estudos futuros para investigar esses outros fatores e sua possível relação com o uso do transporte público coletivo.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

Declaração de contribuição de autoria CRediT

Gabriela Maciel Wagner: Conceitualização; curadoria dos dados; análise dos dados; investigação; metodologia; visualização; redação do manuscrito original. Lino Guimarães Marujo: Redação - revisão e edição

Uso de tecnologia assistida por inteligência artificial

Os autores declaram que não foram utilizadas tecnologias assistidas por inteligência artificial na pesquisa relatada neste artigo e na preparação do seu texto.

Declaração de conflitos de interesse

Os autores declaram não haver conflito de interesses a ser informado.

Data availability statement

Os dados, modelos e códigos que suportam os resultados deste estudo estão disponíveis mediante solicitação ao autor correspondente, Gabriela Maciel Wagner.

References

- Abdullah, M., N. Ali, S. A. Hussain, A. B. Aslam, & M. A. Javid (2021). Measuring changes in travel behavior pattern due to COVID-19 in a developing country: A case study of Pakistan. *Transport Policy* 108, 21–33. DOI:10.1016/j.tranpol.2021.04.023.
- Benavides, F. G., M. Amable, C. Cornelio, A. Vives, L. C. Milián, D. Barraza, D. Bernal, M. Silva-Peñaherrera, & J. Delclos (2021). O futuro do trabalho após a COVID-19: o papel incerto do teletrabalho no domicílio. *Revista Brasileira de Saúde Ocupacional* 46(31), e31. DOI:10.1590/2317-6369000037820.
- Bernal, J. L., S. Cummins, & A. Gasparrini (2017). Interrupted time series regression for the evaluation of public health interventions: a tutorial. *International Journal of Epidemiology* 46(1), 348–355. DOI:10.1093/ije/dyw098.
- Borgatto, A. F. (2000). Análise de intervenção em séries temporais: Aplicações em transporte urbano. Mestrado (dissertação), Universidade Federal de Lavras, Lavras, MG. URL: <https://repositorio.ufla.br/handle/1/15569> [visitado 10/02/2023].
- Cavalcante, J. R. & A. J. L. Abreu (2020). COVID-19 no município do Rio de Janeiro: uma análise espacial da ocorrência dos primeiros casos e óbitos confirmados. *Epidemiologia e Serviços de Saúde* 29(3), e2020204. DOI:10.5123/S1679-49742020000300007.
- CET-Rio (2022). *Diretoria de Engenharia de Tráfego*. Companhia de Engenharia de Tráfego do Rio de Janeiro. URL: <https://cetrio.prefeitura.rio/diretoria-de-engenharia-de-trafego/> [visitado 10/02/2023].
- Conselho Nacional de Saúde (2020, may). Recomendação nº 036, de 11 de maio de 2020. URL: <https://www.gov.br/conselho-nacional-de-saude/pt-br/atos-normativos/recomendacoes/2020/recomendacao-no-036.pdf>.
- Costa, C. S., C. S. Pitombo, & F. L. U. Souza (2022). Travel behavior before and during the COVID-19 Pandemic in Brazil: Mobility changes and transport policies for a sustainable transportation system in the post-pandemic period. *Sustainability* 14(8), 4573. DOI:10.3390/su14084573.

- Data.Rio (2023). *Movimento Médio Diário de Passageiros, Segundo os Transportes Rodoviário, Ferroviário, Hidroviário e Aeroviário no Município do Rio de Janeiro Entre 1995-2022*. Prefeitura do Rio de Janeiro. URL: <https://www.data.rio/documents/f338ce534dd5427cbd9fc780ef63f4cd> [visitado 19/10/2023].
- DETRAN-RJ (2022). *Frota por Tipo de Veículo*. Departamento de Trânsito do Estado do Rio de Janeiro. URL: https://www.detran.rj.gov.br/_estatisticas.veiculos/02.asp [visitado 14/01/2023].
- Freitas, C. M., C. Barcellos, D. A. Villela, G. C. Matta, L. C. Reis, M. C. Portela, D. R. Xavier, R. Guimarães, R. F. Saldanha, & I. V. Mefano (2020). *COVID-19 e o Teletrabalho: Pesquisa de Percepção Antes e Durante a Pandemia na Região Metropolitana do Rio de Janeiro*. Fiocruz. URL: <https://www.arca.fiocruz.br/handle/icict/55828> [visitado 19/10/2023].
- Fuller, D., S. Sahlqvist, S. Cummins, & D. Ogilvie (2012). The impact of public transportation strikes on use of a bicycle share program in London: Interrupted time series design. *Preventive Medicine* 54(1), 74–76. DOI:10.1016/j.ypmed.2011.09.021.
- Góes, G. S., F. S. Martins, & J. A. S. Nascimento (2021). *O Trabalho Remoto e a Pandemia: O Que a PNAD COVID-19 Nos Mostrou*. Brasília: Instituto de Pesquisa Econômica Aplicada. URL: <https://www.ipea.gov.br/cartadeconjuntura/index.php/2021/02/o-trabalho-remoto-e-a-pandemia-o-que-a-pnad-covid-19-nos-mostrou/> [visitado 19/10/2023].
- Hyndman, R. J. & Y. Khandakar (2008). Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software* 27(3), 1–22. DOI:10.18637/jss.v027.i03.
- IBGE (2020). *Pesquisa Nacional por Amostra de Domicílios - PNAD COVID19*. Instituto Brasileiro de Geografia e Estatística. URL: <https://www.ibge.gov.br/estatisticas/sociais/trabalho/27947-divulgacao-mensal-pnadcovid2.html> [visitado 11/02/2023].
- IBGE (2023). *Município do Rio de Janeiro - Panorama*. Instituto Brasileiro de Geografia e Estatística. URL: <https://cidades.ibge.gov.br/brasil/rj/rio-de-janeiro/panorama> [visitado 19/10/2023].
- Lucambio Pérez, F. (2022). *Análise de Séries Temporais*. URL: <http://leg.ufpr.br/~lucambio/STemporais/STemporais.html> [visitado 04/01/2023].
- Morettin, P. A. & C. Toloi (2006). *Análise de Séries Temporais* (2 ed.). São Paulo: Egard Blucher.
- NTU (2021). *Anuário NTU: 2020-2021*. Brasília: Associação Nacional das Empresas de Transportes Urbanos.
- Pereira, T. P., C. S. Albuquerque, V. L. D. Mattos, A. C. Konrath, L. R. Nakamura, & V. C. C. Vargas (2021). Análise de desempenho do teste Ljung-Box na aplicação do modelo SARIMA nos dados mensais da demanda de energia elétrica da classe consumidora comercial do RS. In *Anais do Encontro Nacional de Modelagem Computacional e Encontro de Ciência e Tecnologia de Materiais (Uberlândia, MG)*, Recife. DOI:10.29327/154013.24-22.
- Rodrigues, F. S. (2022). *Aplicação da Análise de Séries Temporais Interrompidas a Um “Experimento Natural”: Avaliação do Impacto da Restrição de Venda de Antimicrobianos Sem Receita Médica Sobre a Etiologia e Resistência Antimicrobiana em Infecções Urinárias em Botucatu (SP)*. Doutorado (tese), Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu. URL: <http://hdl.handle.net/11449/217637> [visitado 04/01/2023].
- Schaffer, A. L., T. A. Dobbins, & S. Pearson (2021). Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. *BMC Medical Research Methodology* 21(1), 58. DOI:10.1186/s12874-021-01235-8.
- Shakibaei, S., G. C. Jong, P. Alpkökin, & T. H. Rashidi (2021). Impact of the COVID-19 pandemic on travel behavior in Istanbul: A panel data analysis. *Sustainable Cities and Society* 65, 102619. DOI:10.1016/j.scs.2020.102619.
- Silva, A. N. R., C. S. Pitombo, J. U. Pedreira Júnior, T. G. M. Ciriaco, & C. S. Costa (2022). Changes in mobility and challenges to the transport sector in Brazil due to COVID-19. In J. Zhang & Y. Hayashi (Eds.), *Transportation Amid Pandemics: Lessons Learned from COVID-19*. Amsterdam: Elsevier.
- SMTR (2022a). *Painéis de Acompanhamento da Operação dos Transportes*. Secretaria Municipal de Transportes do Rio de Janeiro. URL: <https://transportes.prefeitura.rio/informacao-da-operacao-dos-onibus-1/> [visitado 11/02/2023].
- SMTR (2022b). *Subsidio*. Secretaria Municipal de Transportes do Rio de Janeiro. URL: <https://transportes.prefeitura.rio/subsidio/> [visitado 14/06/2023].
- Vos, J. (2020). The effect of COVID-19 and subsequent social distancing on travel behavior. *Transportation Research Interdisciplinary Perspectives* 5, 100121. DOI:10.1016/j.trip.2020.100121.
- Yang, Y., M. Cao, L. Cheng, K. Zhai, X. Zhao, & J. Vos (2021). Exploring the relationship between the COVID-19 pandemic and changes in travel behaviour: A qualitative study. *Transportation Research Interdisciplinary Perspectives* 11, 100450. DOI:10.1016/j.trip.2021.100450.