



Instituto Alberto Luiz Coimbra de
Pós-Graduação e Pesquisa de Engenharia

**ANÁLISE EXPLORATÓRIA DOS DADOS PÚBLICOS PARA AVALIAÇÃO DO
IMPACTO DA PANDEMIA DE COVID-19 NO SISTEMA DE TRANSPORTE PÚBLICO
POR ÔNIBUS NA CIDADE DO RIO DE JANEIRO**

Gabriela Maciel Wagner

Dissertação de Mestrado apresentada ao
Programa de Pós-graduação em Engenharia de
Produção, COPPE, da Universidade Federal do
Rio de Janeiro, como parte dos requisitos
necessários à obtenção do título de Mestre em
Engenharia de Produção.

Orientador: Lino Guimarães Marujo

Rio de Janeiro
Fevereiro de 2024

ANÁLISE EXPLORATÓRIA DOS DADOS PÚBLICOS PARA AVALIAÇÃO DO
IMPACTO DA PANDEMIA DE COVID-19 NO SISTEMA DE TRANSPORTE PÚBLICO
POR ÔNIBUS NA CIDADE DO RIO DE JANEIRO

Gabriela Maciel Wagner

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA DE PRODUÇÃO.

Orientador: Lino Guimarães Marujo

Aprovada por: Prof. Lino Guimarães Marujo

Prof. Roberto Ivo da Rocha Lima Filho

Prof. Marcio de Almeida D'Agosto

Prof. Matheus Henrique de Sousa Oliveira

RIO DE JANEIRO, RJ - BRASIL
FEVEREIRO DE 2024

Wagner, Gabriela Maciel

Análise exploratória dos dados públicos para avaliação do impacto da pandemia de Covid-19 no sistema de transporte público por ônibus na cidade do Rio de Janeiro / Gabriela Maciel Wagner. - Rio de Janeiro: UFRJ/COPPE, 2024.

XII, 91 p.: il.; 29,7 cm.

Orientador: Lino Marujo Guimarães

Dissertação (mestrado) - UFRJ/ COPPE/ Programa de Engenharia de Produção, 2024.

Referências Bibliográficas: p.82-87.

1. Transporte público por ônibus. 2. Pandemia de Covid-19. 3. Séries temporais interrompidas. I. Marujo, Lino Guimarães. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Produção. III. Título.

AGRADECIMENTOS

Agradeço, primeiro, a Deus por ter me dado força e sabedoria ao longo dessa trajetória, sempre iluminando meus caminhos e por tudo que me foi permitido. Aos meus pais, Celina e Denilson, por sempre estarem ao meu lado e pelo apoio para concluir mais essa etapa da minha vida. Ao meu noivo, Janderson, por toda a compreensão e incentivo desde o início dessa trajetória. Agradeço ao meu orientador, prof. Lino Marujo, que desde o primeiro contato sempre esteve disposto a me ajudar e orientar, e por todo o conhecimento transmitido. A todo o corpo docente do Programa de Engenharia de Produção pelos conhecimentos transmitidos, que forneceram base para meu desenvolvimento e engrandecimento acadêmico e pessoal. Agradeço a todos aqueles que direta ou indiretamente contribuíram de alguma forma para essa conquista. Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

**ANÁLISE EXPLORATÓRIA DOS DADOS PÚBLICOS PARA AVALIAÇÃO DO
IMPACTO DA PANDEMIA DE COVID-19 NO SISTEMA DE TRANSPORTE PÚBLICO
POR ÔNIBUS NA CIDADE DO RIO DE JANEIRO**

Gabriela Maciel Wagner

Fevereiro/2024

Orientador: Lino Guimarães Marujo

Programa: Engenharia de Produção

A pandemia de COVID-19 desencadeou mudanças no comportamento de viagens, com aumento no uso do transporte individual e redução no transporte público. Diante desse contexto, o sistema de transporte público por ônibus enfrentou desafios significativos, sofrendo uma substancial redução da demanda. Este estudo visa avaliar o impacto da pandemia no transporte público por ônibus no município do Rio de Janeiro. Além disso, busca examinar o uso do transporte individual, a adoção do trabalho remoto e investigar como esses elementos se correlacionam com a diminuição da utilização do transporte público por ônibus. Na análise, baseada em dados públicos, foram aplicadas técnicas de modelagem de séries temporais e análise exploratória. Os modelos selecionados estimaram uma redução de 29,47% no número de passageiros transportados e uma contração de 25,75% na quantidade de viagens entre março de 2020 e dezembro de 2022. Por outro lado, observou-se um aumento constante na frota de veículos individuais nos últimos anos, enquanto o fluxo de veículos apresentou uma diminuição de 8,4% na média mensal após a pandemia em comparação com o período anterior. A análise do trabalho remoto indica uma redução gradual ao longo dos meses do período pandêmico, sugerindo uma possível retomada às atividades presenciais. O perfil socioeconômico das pessoas que adotaram o trabalho remoto revela uma maior propensão a gastos com transporte individual. A continuidade da adoção do trabalho remoto pode ser um fator que contribui para a manutenção de níveis de tráfego veicular ligeiramente inferiores aos observados na pré-pandemia. Esses resultados destacam algumas alterações nos padrões de mobilidade decorrentes da crise sanitária.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

EXPLORATORY ANALYSIS OF PUBLIC DATA TO ASSESS THE IMPACT OF THE COVID-19 PANDEMIC ON THE PUBLIC BUS TRANSPORTATION SYSTEM IN THE CITY OF RIO DE JANEIRO

Gabriela Maciel Wagner

February/2024

Advisor: Lino Guimarães Marujo

Department: Production Engineering

The COVID-19 pandemic has caused changes in travel behavior, with an increase in the use of individual transportation and a reduction in public transportation. In this context, the bus public transportation system has faced significant challenges, experiencing a substantial decrease in demand. This study aims to assess the impact of the pandemic on bus public transportation in the city of Rio de Janeiro. Additionally, it seeks to examine the use of individual transportation, the adoption of remote work, and investigate how these elements correlate with the decline in the use of bus public transportation. In the analysis, based on public data, time series modeling and exploratory analysis techniques were applied. The selected models estimated a 29,47% reduction in the number of passengers transported and a contraction of 25,75% in the quantity of trips between March 2020 and December 2022. On the other hand, continuous increase in the fleet of individual vehicles has been observed in recent years, while vehicle flow showed an 8,4% decrease in monthly average after the pandemic compared to the previous period. The analysis of remote work indicates a gradual reduction over the months of the pandemic period, suggesting a possible return to in-person activities. The socio-economic profile of people who adopted remote work shows a greater inclination towards spending on individual transportation. The continued adoption of remote work may be a factor contributing to maintaining slightly lower vehicular traffic levels than those observed pre-pandemic. These results highlight some alterations in mobility patterns resulting from the health crisis.

SUMÁRIO

1 INTRODUÇÃO.....	1
1.1 CONSIDERAÇÕES INICIAIS.....	1
1.2 OBJETIVOS.....	1
1.2.1 Objetivo geral.....	1
1.2.2 Objetivos específicos.....	2
1.3 JUSTIFICATIVA.....	2
1.4 ESTRUTURA DA DISSERTAÇÃO.....	3
2 REFERENCIAL TEÓRICO.....	4
2.1 COMPORTAMENTO DE VIAGENS DURANTE A PANDEMIA DE COVID-19.....	4
2.2 SÉRIES TEMPORAIS.....	5
2.3 ANÁLISE DE SÉRIES TEMPORAIS INTERROMPIDAS.....	7
2.3.1 Modelo de regressão segmentada.....	9
2.3.2 Modelo ARIMA.....	11
2.3.3 Aplicações de análise de séries temporais interrompidas.....	13
3 METODOLOGIA.....	15
3.1 LOCAL DO ESTUDO.....	15
3.1.1 Sistema de transporte público por ônibus do município do Rio de Janeiro.....	15
3.1.2 Desempenho operacional do sistema do transporte público por ônibus do município do Rio de Janeiro.....	17
3.1.2.1 Passageiros transportados.....	17
3.1.2.2 Viagens realizadas e quilometragem percorridos.....	18
3.1.2.3 Índice de passageiros por quilômetro (IPK) e índice de passageiros equivalentes por quilômetro (IPKe).....	19
3.2 COLETA DOS DADOS.....	20
3.3 FERRAMENTAS DE ANÁLISE DOS DADOS.....	22
3.3.1 Séries temporais interrompidas.....	22
3.3.2 Aplicação do modelo de regressão segmentada.....	24
3.3.3 Aplicação do modelo ARIMA.....	26
3.3.4 Avaliação do modelo.....	29
3.3.5 Análise exploratória.....	30
4 RESULTADOS E DISCUSSÃO.....	33
4.1 QUANTIDADE DE PASSAGEIROS TRANSPORTADOS.....	33
4.1.1 Aplicação do modelo de regressão segmentada.....	35
4.1.2 Aplicação do modelo ARIMA.....	38
4.1.3 Comparação entre os modelos.....	45
4.2 QUANTIDADE DE VIAGENS REALIZADAS.....	47
4.2.1 Aplicação do modelo de regressão segmentada.....	49
4.2.2 Aplicação do modelo ARIMA.....	51

4.3 QUANTIDADE DE PASSAGEIROS TRANSPORTADOS VERSUS QUANTIDADE DE VIAGENS REALIZADAS.....	57
4.4 INDICADOR GLOBAL DE VOLUME VEICULAR (IGVOL).....	62
4.5 FROTA DE VEÍCULOS INDIVIDUAIS.....	66
4.6 TRABALHO REMOTO.....	72
5 CONSIDERAÇÕES FINAIS.....	79
REFERÊNCIAS BIBLIOGRÁFICAS.....	82
APÊNDICE A.....	88
APÊNDICE B.....	90

LISTA DE FIGURAS

Figura 1 - Componentes de uma série temporal.....	6
Figura 2 - Exemplos de efeitos de uma intervenção em séries temporais.....	8
Figura 3 - Representação gráfica do modelo de regressão segmentada ajustado a dados de séries temporais interrompidas.....	10
Figura 4 - Consórcios do sistema de transporte público por ônibus do município do Rio de Janeiro.....	16
Figura 5 - Mapa das estações de BRT do município do Rio de Janeiro.....	16
Figura 6 - Evolução do número de passageiros transportados entre 2015 a 2022.....	17
Figura 7 - Distribuição das gratuidades (a) entre 2015 a 2019 e (b) entre 2020 a 2022.....	18
Figura 8 - Evolução (a) quantidade de viagens e (b) quilômetros percorridos entre 2015 e 2022.....	19
Figura 9 - Evolução do índice de passageiros por quilômetro e do índice de passageiros equivalentes por quilômetro entre 2015 a 2022.....	20
Figura 10 - Evolução do número de passageiros transportados e quantidade de viagens realizadas entre 2000 a 2022.....	24
Figura 11 - Teste de Durbin-Watson para correlação dos resíduos.....	26
Figura 12 - Procedimento para a seleção do modelo ARIMA.....	29
Figura 13 - Fluxograma do procedimento metodológico.....	32
Figura 14 - Série temporal do número de passageiros transportados.....	33
Figura 15 - Representação do modelo de regressão segmentada da série temporal do número de passageiros transportados.....	36
Figura 16 - Resíduos do modelo de regressão segmentada da série temporal do número de passageiros transportados.....	37
Figura 17 - Contrafactual com base no modelo de regressão segmentada da série temporal do número de passageiros transportados.....	38
Figura 18 - Número de passageiros transportados e valor médio por mês de janeiro de 2015 a dezembro de 2019.....	38
Figura 19 - Decomposição da série temporal do número de passageiros transportados.....	39
Figura 20: Série temporal do número de passageiros transportados (a) não estacionária e (b) estacionária.....	40
Figura 21 - Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da série temporal do número de passageiros transportados (a) e (b) não estacionária e (c) e (d) estacionária.....	41
Figura 22 - Resíduos do modelo SARIMA(0,1,1)(2,0,0)12 da série temporal do número de passageiros transportados.....	43
Figura 23 - Valores observados e valores previstos na ausência da pandemia com base no modelo SARIMA(0,1,1)(2,0,0)12 da série temporal do número de passageiros transportados... 44	
Figura 24 - Resíduos do modelo de regressão segmentada e ARIMA da série temporal do número de passageiros transportados.....	46
Figura 25 - Série temporal da quantidade de viagens realizadas.....	47

Figura 26 - Representação do modelo de regressão segmentada da série temporal da quantidade de viagens realizadas.....	50
Figura 27 - Resíduos do modelo de regressão segmentada da série temporal da quantidade de viagens realizadas.....	51
Figura 28 - Decomposição da série temporal da quantidade de viagens realizadas.....	52
Figura 29 - Quantidade de viagens realizadas e valor médio por mês de janeiro de 2015 a dezembro de 2019.....	52
Figura 30 - Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da série temporal da quantidade de viagens realizadas (a) e (b) antes da diferenciação e (c) e (d) depois da diferenciação de primeira ordem e sazonal.....	53
Figura 31 - Resíduos do modelo SARIMA(0,1,1)(2,0,0)12 da série temporal da quantidade de viagens realizadas.....	55
Figura 32 - Valores observados e valores previstos na ausência da pandemia com base no modelo SARIMA(2,1,1)(2,0,0)12 da série temporal da quantidade de viagens realizadas.....	57
Figura 33 - Evolução do número de passageiros transportados e quantidade de viagens realizadas.....	58
Figura 34 - Média anual da frota operante entre 2015 a 2022.....	59
Figura 35- Variação percentual mensal da demanda e da oferta em relação a fevereiro de 2020.....	59
Figura 36 - Coeficiente de aglomeração entre março de 2020 a dezembro de 2022.....	61
Figura 37 - Vias com monitoramento de tráfego.....	62
Figura 38 - Evolução mensal do indicador global de volume veicular entre janeiro de 2016 a dezembro de 2022.....	63
Figura 39 - Evolução mensal do indicador global de volume veicular entre março de 2020 a dezembro de 2022.....	65
Figura 40 - Frota de automóveis e motocicletas e taxa de motorização.....	68
Figura 41 - Distribuição das principais despesas de consumo por classes de rendimento.....	69
Figura 42 - Proporção dos gastos com transporte urbano e transporte individual nas despesas de transporte por classes de rendimento.....	70
Figura 43 - Variação mensal da frota de automóveis e motocicletas entre janeiro de 2015 a dezembro de 2022.....	72
Figura 44 - Porcentagem de pessoas em trabalho remoto entre maio de 2020 a novembro de 2020.....	73

LISTA DE TABELAS

Tabela 1 - Endereço eletrônico dos dados coletados.....	22
Tabela 2 - Número de passageiros transportados e variação percentual.....	34
Tabela 3 - Estatísticas descritivas do número de passageiros transportados.....	34
Tabela 4 - Resultado dos parâmetros do modelo de regressão segmentada da série temporal do número de passageiros transportados.....	35
Tabela 5 - Teste de Dickey-Fuller Aumentado da série temporal do número de passageiros transportados.....	40
Tabela 6 - Resultado dos parâmetros do modelo SARIMA(0,1,1)(2,0,0)12 da série temporal do número de passageiros transportados.....	42
Tabela 7 - Métricas de avaliação do modelo de regressão segmentada e do modelo ARIMA da série temporal do número de passageiros transportados.....	46
Tabela 8 - Quantidade de viagens realizadas e variação percentual.....	48
Tabela 9 - Estatísticas descritivas da quantidade de viagens realizadas.....	49
Tabela 10 - Resultado dos parâmetros do modelo de regressão segmentada da série temporal da quantidade de viagens realizadas.....	50
Tabela 11 - Resultado dos parâmetros do modelo SARIMA(2,1,1)(2,0,0)12 da série temporal da quantidade de viagens realizadas.....	54
Tabela 12 - Métricas de avaliação do modelo de regressão segmentada e do modelo ARIMA da série temporal da quantidade de viagens realizadas.....	56
Tabela 13 - Indicador global de volume veicular e variação percentual.....	64
Tabela 14 - Estatísticas descritivas do indicador global de volume veicular.....	64
Tabela 15 - Frota de automóveis e motocicletas no município do Rio de Janeiro.....	67
Tabela 16 - Perfil das pessoas em trabalho remoto entre maio de 2020 a novembro de 2020.	74
Tabela 17 - Distribuição das pessoas em trabalho remoto por atividade, ocupação e rendimento.....	75
Tabela 18 - Percentual das pessoas que realizaram trabalho, trabalho remoto e teletrabalho no domicílio.....	77
Tabela 19 - Perfil das pessoas que realizaram teletrabalho no domicílio em 2022.....	77

LISTA DE SIGLAS

BRT	<i>Bus Rapid Transit</i>
ANTP	Associação Nacional de Transportes Públicos
CET-Rio	Companhia de Engenharia de Tráfego do Rio de Janeiro
CMTC	Companhia Municipal de Transportes Coletivos
DETRAN-RJ	Departamento de Trânsito do Estado do Rio de Janeiro
FETRANSPOR	Federação das Empresas de Transportes de Passageiros do Estado do Rio de Janeiro
IBGE	Instituto Brasileiro de Geografia e Estatística
IGVOL	Indicador Global de Volume Veicular
PDF	<i>Portable Document Format</i>
PNAD	Pesquisa Nacional por Amostra de Domicílios
POF	Pesquisa de Orçamentos Familiares
OMS	Organização Mundial da Saúde
SMTR	Secretaria Municipal de Transportes

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

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, ainda de acordo com Vos, a Organização Mundial da Saúde (doravante OMS) declarou a COVID-19 como uma pandemia. 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, destaca 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 transportes. 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 (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 crítica redução da demanda do transporte público por ônibus desde março de 2020 soma-se à tendência expressiva de queda das últimas décadas.

1.2 OBJETIVOS

1.2.1 Objetivo geral

O objetivo principal deste trabalho consiste em avaliar as mudanças no comportamento de viagens decorrentes das medidas de distanciamento social implementadas

durante a pandemia de COVID-19, concentrando-se nos efeitos sobre a demanda do transporte público por ônibus.

1.2.2 Objetivos específicos

Os seguintes objetivos específicos foram estabelecidos visando alcançar o objetivo principal deste trabalho:

- a) Avaliar o impacto da pandemia na demanda e oferta do transporte público por ônibus através da modelagem de séries temporais interrompidas;
- b) Analisar o comportamento histórico da demanda e oferta nos últimos anos, com ênfase no período subsequente à pandemia de COVID-19;
- c) Analisar os principais indicadores do desempenho operacional do transporte público por ônibus;
- d) Analisar a evolução da frota de veículos individuais motorizados e o volume de tráfego, avaliando seu comportamento com as medidas de distanciamento social;
- e) Investigar uma possível correlação entre a taxa de motorização da população, o volume de tráfego e a demanda do transporte público por ônibus;
- f) Avaliar a adoção do trabalho remoto como prática decorrente da pandemia de COVID-19 e investigar se essa mudança impactou no volume de tráfego e na demanda do transporte público por ônibus.

1.3 JUSTIFICATIVA

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. Contudo, apesar dos diversos estudos realizados com essa finalidade, poucos utilizaram dados públicos e conduziram análises estatísticas para avaliar o comportamento dos dados antes e durante a pandemia, mensurar os impactos e investigar a relação entre eles.

O presente trabalho se insere neste momento de transição e busca analisar as mudanças comportamentais e possíveis mudanças estruturais na mobilidade urbana devido às restrições de locomoção ocasionadas pela pandemia. Pesquisadores afirmam a importância de compreender o impacto da pandemia de COVID-19, em função de investigar o advento de novas relações pessoais e comerciais, o desenvolvimento de políticas relacionadas ao transporte para o mundo pós-COVID-19 e as mudanças e os efeitos relacionados a pandemia se tornarem permanentes (GOES *et al.*, 2021; ABDULLAH *et al.*, 2021; YANG *et al.*, 2021).

Nesse contexto, o trabalho se baseou na coleta e análise de bases de dados públicas disponíveis na internet, que possibilitou demonstrar estas mudanças comportamentais relacionadas à utilização do transporte público, uso do transporte individual e adesão ao trabalho remoto.

1.4 ESTRUTURA DA DISSERTAÇÃO

O trabalho foi organizado em cinco capítulos que serão apresentados a seguir.

O primeiro capítulo contextualiza o tema, abordando a caracterização do problema e as motivações que conduziram a esta pesquisa, assim como a exposição dos objetivos geral e específicos do trabalho.

No segundo capítulo consta o referencial teórico, no qual serão apresentados estudos que evidenciaram as mudanças nos padrões de deslocamento decorrentes da pandemia de COVID-19. Adicionalmente, introduziu-se uma explicação sobre séries temporais, destacando a aplicação de séries temporais interrompidas.

O terceiro capítulo delineou o local do estudo, descrevendo as características do sistema de transporte público por ônibus. Este capítulo também detalhou a metodologia empregada, incluindo a coleta e análise dos dados por meio de séries temporais interrompidas, e análise exploratória.

No quarto capítulo, apresentaram-se os resultados obtidos com a aplicação de séries temporais interrompidas, utilizadas para avaliar o impacto da pandemia nas séries temporais da demanda e oferta do transporte público por ônibus. Além disso, analisou-se a evolução temporal dessas duas variáveis, evidenciando suas flutuações e as correlações observadas ao longo do período. O capítulo também contemplou a análise do volume de tráfego e frota de veículos nos últimos anos, examinando as alterações de comportamento durante a pandemia, bem como a adoção do trabalho remoto como uma alternativa no período pandêmico, investigando seu possível impacto na mobilidade urbana.

No capítulo cinco, são apresentadas as considerações finais, destacando os principais resultados obtidos, as limitações identificadas e apontando recomendações para pesquisas futuras.

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 com a 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 *et al.*, 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.

Shakibaei *et al.* (2021) conduziram uma pesquisa em Istambul, na Turquia, com o objetivo de compreender as alterações nos padrões de deslocamento das pessoas com a pandemia e determinar quais dessas mudanças permaneceram. Antes da pandemia, o principal meio de transporte para o deslocamento até o trabalho era o transporte público, como ônibus e BRT, seguido por carro próprio e, em terceiro lugar, o transporte ferroviário. Com o advento da pandemia, observou-se um aumento no número de pessoas que passaram a utilizar carro particular em detrimento do transporte público. Contudo, conforme os casos em Istambul aumentaram, a adoção do teletrabalho e da educação a distância superou o uso de carros.

Em outro estudo, Abdullah *et al.* (2021) buscaram compreender os padrões de viagem das pessoas no Paquistão antes e durante a crise sanitária. Antes da pandemia, 55% das pessoas declaravam que o trabalho era o principal motivo de suas viagens, mas esse percentual reduziu para 51% durante a pandemia, atribuído ao aumento do trabalho remoto. Da mesma forma, o objetivo principal de viagens relacionadas à educação reduziu de 30% para 22%, indicando uma mudança para atividades remotas. Além disso, o estudo destacou uma mudança significativa no objetivo principal de deslocamento, passando de trabalho e estudo para compras. Observou-se também que, para viagens de curtas distâncias, a mudança do transporte público para o carro próprio não foi significativa, mas para viagens de longa distância essa transição foi mais perceptível.

Um estudo qualitativo conduzido em Huzhou, na China, reforça que os padrões de viagem foram impactados durante a pandemia. As pessoas evitaram o transporte público devido à sua propensão para a disseminação de vírus, resultando em uma maior utilização de carros particulares (YANG, 2021). Além disso, as pessoas escolheram alternativas como bicicletas e caminhadas para se deslocarem em distâncias curtas.

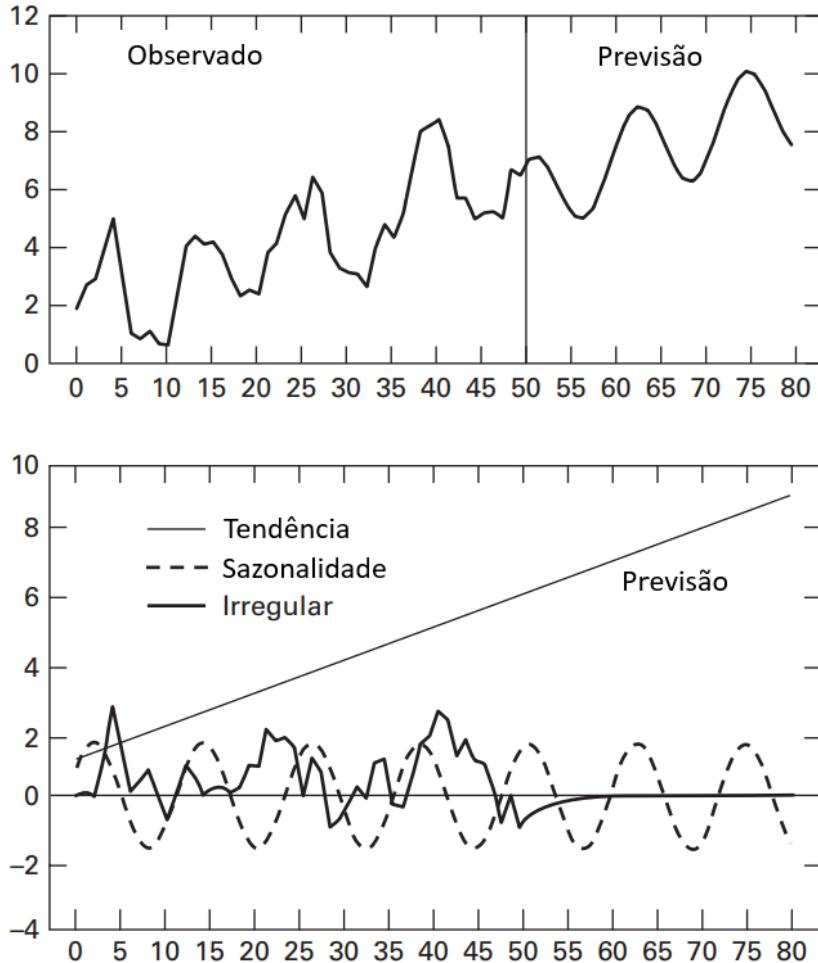
No Brasil, Costa *et al.* (2022) realizou uma pesquisa com o objetivo de analisar os perfis de deslocamento antes e durante a pandemia em vários estados do país. O autor constatou que os modos de transporte mais utilizados antes da pandemia eram o carro, o transporte público por ônibus e o *ridesourcing*, 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 também ocorreu uma redução no número de viagens para o trabalho devido ao crescimento do teletrabalho com as medidas de distanciamento.

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

Uma série temporal é um conjunto de observações dispostas sequencialmente em intervalos iguais ao longo do tempo (SCHAFFER *et al.*, 2021). A análise de séries temporais visa a construção de um modelo com a finalidade de fazer previsões de valores futuros, assim como, descrever o comportamento da série, verificando a existência de tendências, sazonalidade e ciclos (MORETTIN; TOLOI, 2006). Uma série pode conter os seguintes componentes: tendência, sazonalidade, ciclos e variações irregulares, conforme ilustra a Figura 1. O componente de tendência representa o comportamento de aumento ou diminuição dos dados ao longo do tempo, a sazonalidade representa o padrão relacionado a um determinado período de tempo e os ciclos representam um movimento periódico regular não associado a uma medida temporal (ENDERS, 2014).

Figura 1 - Componentes de uma série temporal.



Fonte: Adaptado de Enders (2014)

As séries temporais possuem algumas características comuns, como a estacionariedade e a autocorrelação.

Uma série estacionária é aquela que possui média, variância e covariância constantes ao longo do tempo (SCHAFFER *et al.*, 2021). Em outras palavras, as propriedades da série não são afetadas por uma mudança na origem do tempo (MONTGOMERY *et al.*, 2008). Portanto, séries temporais com tendência ou sazonalidade não são estacionárias, pois esses componentes influenciam o valor da série em momentos diferentes. Na prática, a maioria das séries temporais não são estacionárias, entretanto séries temporais não-estacionárias podem se tornar estacionárias através da diferenciação, que consiste na diferença entre o valor de uma observação pelo valor da observação anterior (HYNDMAN; ATHANASOPOULOS, 2018). Os autores complementam dizendo que além dessa diferenciação, às vezes é necessário a diferenciação sazonal para deixar a série estacionária, que consiste na diferença entre o valor de uma observação pelo valor da observação anterior do mesmo período. A diferenciação

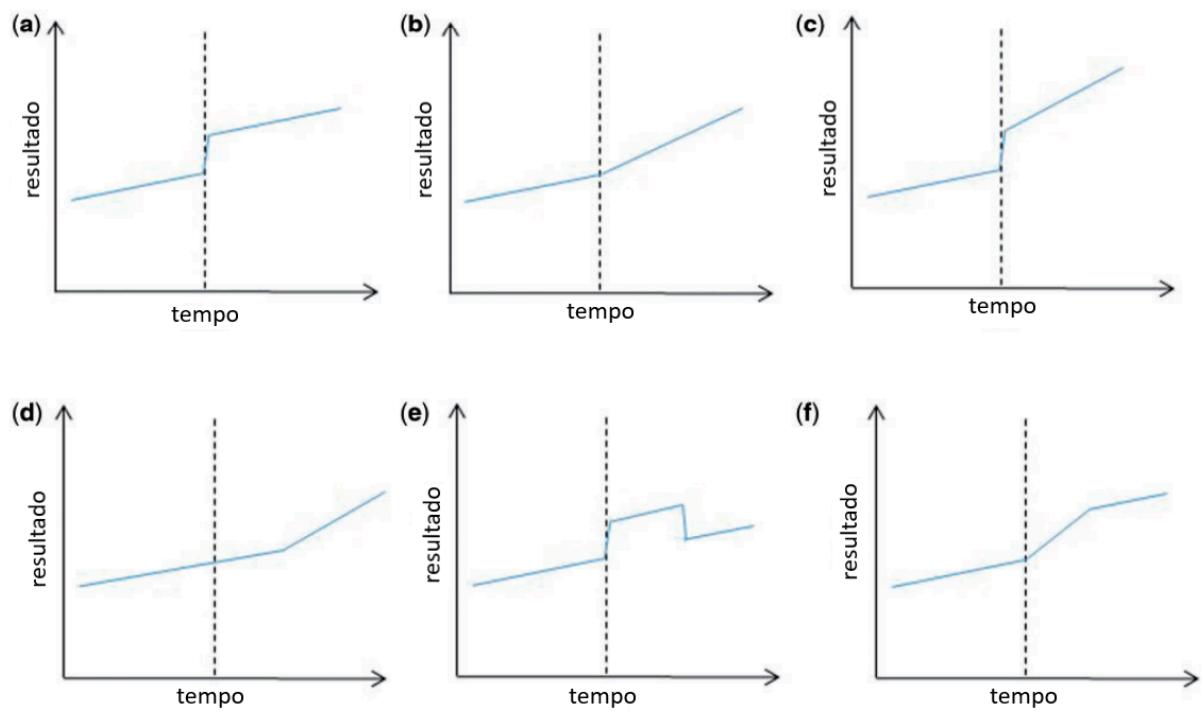
pode ajudar a estabilizar a média e variância da série, dessa forma eliminando ou reduzindo a tendência e a sazonalidade da série.

A autocorrelação é a correlação entre as observações da série e as observações em pontos de tempo anteriores, ou seja, é a relação linear entre valores defasados da série temporal. A função de autocorrelação (ACF) e autocorrelação parcial (PACF) podem ser utilizadas para analisar a autocorrelação da série. De acordo com Hyndman e Athanasopoulos (2018), séries temporais com tendência tendem a ter valores positivos que reduzem lentamente à medida que as defasagens aumentam na função de autocorrelação (ACF). Já séries com sazonalidade costumam apresentar valores maiores para as defasagens múltiplas da frequência sazonal do que para outras defasagens. Quando a série possui tendência e sazonalidade observa-se uma combinação desses efeitos nas funções de autocorrelação.

2.3 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, a 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 *et al.*, 2017). A Figura 2 ilustra alguns efeitos de intervenção sobre uma série temporal.

Figura 2 - Exemplos de efeitos de uma intervenção em séries temporais.



Fonte: Adaptado de Bernal *et al.* (2016)

Na Figura 2, observa-se (a) a série temporal apresenta mudança de nível imediata e permanente, (b) ocorre uma mudança imediata na tendência com duração permanente na série temporal (c) a série temporal apresenta uma mudança de nível imediata e gradual de tendência com duração permanente, (d) a mudança de tendência na série temporal ocorre um período de tempo após a intervenção de maneira gradual, (e) ocorre uma mudança de nível imediata com duração temporária na série temporal e (f) a série temporal apresenta uma mudança temporária de tendência e uma mudança permanente de nível.

Existem vários tipos de efeitos que podem ser observados após uma intervenção. De acordo com Schaffer *et al.* (2021) os três principais são: mudança de nível, impulso e rampa. Considerando T_0 o instante inicial que ocorreu a intervenção, esses efeitos podem ser representados da seguinte forma de acordo com os mesmos autores:

- 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.

$$S_t = \begin{cases} 0, & \text{if } t < T_0 \\ 1, & \text{if } t \geq T_0 \end{cases}$$

- 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.

$$P_t = \begin{cases} 0, & \text{if } t \neq T_0 \\ 1, & \text{if } t = T_0 \end{cases}$$

- 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.

$$R_t = \begin{cases} 0, & \text{if } t < T_0 \\ t - T_0 + 1, & \text{if } t \geq T_0 \end{cases}$$

O efeito de uma intervenção pode ser representado por uma combinação de variáveis, levando em consideração sua natureza e duração. Por exemplo, observa-se na Figura 2(c) tanto uma alteração no nível quanto na inclinação da série, indicando que a modelagem do efeito da intervenção deve ser através das variáveis mudança de nível e rampa.

2.3.1 Modelo de regressão segmentada

O modelo de regressão segmentada é um dos recursos para a análise de séries temporais interrompidas, no qual é possível observar e estimar a mudança de nível e a tendência dos segmentos. Cada segmento de uma série temporal possui um nível e uma tendência. Antunes e Cardoso (2015) define nível como o valor inicial da série em cada segmento e tendência como a mudança percentual dos valores ao longo do tempo compreendido pelo segmento.

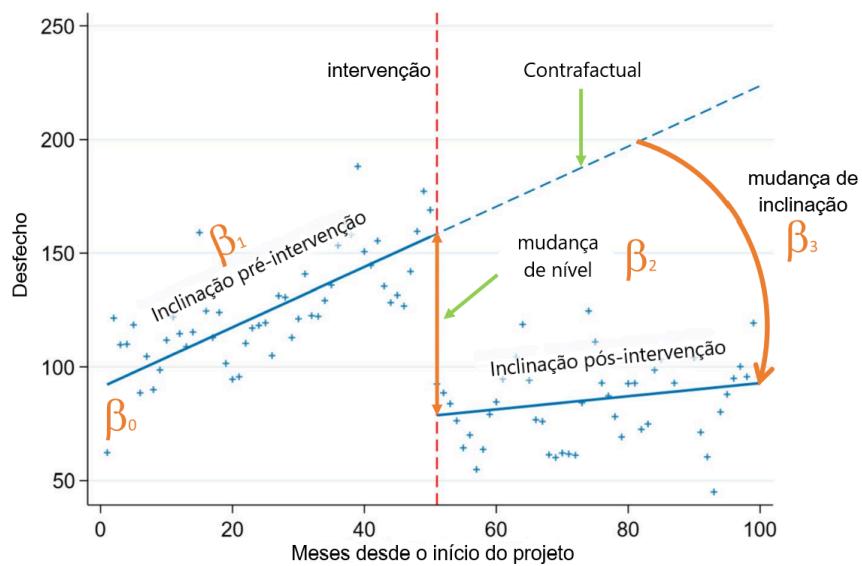
No modelo de regressão segmentada é necessário no mínimo três variáveis, a variável tempo que indica o tempo decorrido desde o início do estudo na frequência que as observações foram feitas, a variável intervenção que indica o período pré-intervenção e o período pós-intervenção, e a variável tempo após a intervenção que indica o tempo decorrido desde o início da intervenção (RODRIGUES, 2022). A Equação 1 apresenta o modelo, na qual Y_t é o valor previsto da variável dependente (Y) no tempo t , β_0 estima o nível de referência no início da série, β_1 representa a tendência pré-intervenção, β_2 estima a mudança de nível pós-intervenção e β_3 indica a mudança de tendência pós-intervenção e ϵ_t o erro aleatório (WAGNER *et al.*, 2002).

$$Y_t = \beta_0 + \beta_1 * tempo\ t + \beta_2 * intervenção\ t + \beta_3 * tempo\ após\ intervenção\ t + e_t \quad (1)$$

A variável intervenção recebe o valor 0 para os pontos anteriores à intervenção e o valor 1 para os pontos a partir do início da intervenção até o seu fim. A variável tempo após a intervenção recebe valores sequenciais de indicação do tempo a partir da intervenção e nos pontos anteriores à intervenção o valor é igual a 0. Como apresentado anteriormente, modelando os efeitos de mudança de nível e de tendência.

A Figura 3 representa graficamente o modelo de regressão segmentada. Observa-se os dois segmentos da série e verifica-se a mudança de nível e a mudança de tendência após a intervenção. Além disso, é representado o contrafactual, ou seja, um cenário hipotético no qual se considera a ausência da intervenção e a tendência da série permanece a mesma, com isso é possível comparar a evolução do impacto da intervenção avaliando as mudanças que ocorreram no período após a intervenção (BERNAL *et al.*, 2017). A apresentação gráfica dos resultados da análise de séries temporais interrompidas, possibilita compararmos visualmente o padrão da série antes da intervenção com o padrão da série após a intervenção e avaliar as mudanças que ocorreram em seu comportamento (WAGNER *et al.*, 2002). Ainda nesse sentido, os autores afirmam que a intuitiva apresentação gráfica dos resultados dos estudos de séries temporais interrompidas é uma das maiores vantagens desse tipo de análise, sendo a inspeção visual o primeiro passo para analisar os dados de uma série temporal.

Figura 3 - Representação gráfica do modelo de regressão segmentada ajustado a dados de séries temporais interrompidas.



Fonte: Adaptado de Turner *et al.* (2021)

O modelo de regressão segmentada permite avaliarmos o impacto de uma intervenção em uma variável, contudo existem algumas limitações no modelo que podem interferir no ajuste de propriedades comuns a séries temporais, como sazonalidade e autocorrelação, exigindo a aplicação de outros modelos matemáticos. De acordo com Bernal *et al.* (2017) a sazonalidade pode influenciar os resultados de duas formas, em primeiro lugar, se houver uma distribuição desigual dos pontos antes e depois da intervenção, prejudicando a identificação dos padrões cíclicos de cada segmento, em segundo lugar, os pontos de um instante de tempo tendem a ser mais semelhantes aos pontos vizinhos no mesmo período, resultando em autocorrelação e superdispersão. Enquanto a autocorrelação viola uma das suposições dos modelos de regressão, que é independência das observações, e não corrigir a autocorrelação pode levar a subestimação dos erros padrões e superestimação da significância dos efeitos da intervenção (WAGNER *et al.*, 2002). Para lidar com a autocorrelação sugere-se utilizar a modelagem ARIMA ou regressão de Prais–Winsten (WAGNER *et al.*, 2002 ; BERNAL *et al.*, 2017).

2.3.2 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 no do mês seguinte, e essa correlação pode se manifestar em intervalos anuais, especialmente em eventos sazonais (RODRIGUES, 2022). Pérez (2022) complementa afirmando que em séries temporais é necessário levar em consideração que a variável resposta seja influenciada pelos valores passados das variáveis preditoras, assim como por seus próprios valores passados. Modelos regressivos estimam o valor de uma variável dependente usando uma combinação linear das variáveis independentes, enquanto modelos autorregressivos estimam o valor usando 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 possuem alguma forma de não-estacionariedade, como tendência e sazonalidade (MORETTIN; TOLOI, 2006). Os modelos ARIMA são capazes de descrever o comportamento de séries estacionárias e não-estacionárias.

Um modelo autorregressivo (AR) é descrito matematicamente como mostra a Equação 2, na qual yt é estimada por um ou múltiplos valores passados de yt , c é uma constante, ϕ é a magnitude da autocorrelação, p é o número de defasagens e ϵt é o erro (HYNDMAN; KHANDAKAR, 2008).

$$yt = c + \phi_1yt - 1 + \phi_2yt - 2 + \dots + \phi_qyt - p + \varepsilon_t \quad (2)$$

Um modelo de médias móveis (MA) usa erros de previsão passados para estimar yt . Sua representação matemática está disposta na Equação 3, na qual yt 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.

$$yt = c + \varepsilon_t + \theta_1\varepsilon_{t-1} + \theta_2\varepsilon_{t-2} + \dots + \theta_q\varepsilon_{t-q} \quad (3)$$

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, conforme mencionado anteriormente. A diferenciação consiste na diferença entre o valor de uma observação pelo valor da observação anterior, como demonstrado na Equação 4.

$$y't = yt - yt - 1 \quad (4)$$

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*, que significa autorregressivo integrado de média móvel. O modelo pode ser escrito matematicamente como apresentado na Equação 5, na qual $y't$ corresponde a série diferenciada (HYNDMAN; KHANDAKAR, 2008).

$$y't = c + \phi_1y't - 1 + \dots + \phi_qy't - q + \varepsilon_t \quad (5)$$

O modelo ARIMA é representado pela notação ARIMA(p,d,q), composto por três parâmetros, no qual “p” é a ordem da parte autoregressiva, “d” é o grau de diferenciação e “q” é a ordem da parte de média móvel. Para séries temporais que apresentam sazonalidade, utiliza-se o modelo SARIMA, autoregressivo integrado de média móvel sazonal, 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, estimativa dos parâmetros e verificação do modelo ajustado (MORETTIN; TOLOI, 2006).

2.3.3 Aplicações de análise de séries temporais interrompidas

A análise de séries temporais interrompidas é uma abordagem utilizada em diversas áreas, incluindo economia, ciências sociais, ciência política, saúde, meio ambiente e muitas outras áreas de estudo.

Wagner *et al.*(2002) utilizaram a análise de série temporais interrompidas visando avaliar o efeito da restrição do número de prescrições de medicamentos por paciente na série temporal da média do número de prescrições por mês em Massachusetts, nos Estados Unidos. Aplicando o modelo de regressão segmentada observaram que com a implementação do limite máximo de três prescrições por mês, a série sofreu uma mudança abrupta de nível, com a redução da média de prescrições de cinco por paciente para menos de três por paciente, com pouca variação de um mês para o outro, tanto no período pré-intervenção como no pós-intervenção. Onze meses após a implementação dessa política, substitui-se por outra, na qual ao invés de restringir a quantidade de medicamentos implementou-se o copagamento de \$1. Após essa nova política, houve uma mudança tanto de nível como de tendência, aumentando a média de prescrições para 4,7 por paciente.

Visando demonstrar a aplicação do uso de séries temporais interrompidas, Bernal *et al.*(2017) utilizaram regressão segmentada para avaliar o impacto na saúde pública com a implementação de regulamentações proibindo o uso de cigarros em lugares fechados na Itália em janeiro de 2015. Os autores analisaram a evolução do diagnóstico de eventos coronarianos agudos entre as pessoas até 69 anos. Analisando visualmente a representação gráfica da série temporal da taxa de eventos coronarianos agudos, os autores observaram que a maioria dos pontos no período pós-intervenção estavam abaixo da linha contrafactual, sugerindo uma redução da taxa. Utilizando a regressão de Poisson, constataram que houve uma redução de 11% nas internações com casos de eventos coronarianos agudos.

Outro estudo com o objetivo de analisar o efeito da introdução de uma política de saúde foi realizado por Schaffer *et al.* (2021), entretanto utilizaram a modelagem ARIMA para estimar o impacto dessa política. A política restringiu as condições de subsídio de um medicamento antipsicótico, o quetiapina. Antes da implementação da política, a população

podia renovar a prescrição médica por 5 vezes, após a política a renovação da prescrição foi suspensa, justificada pela preocupação de prescrições inadequadas. A série temporal analisada foi a quantidade mensal de dispensações do medicamento. Comparando os valores previstos usando o modelo selecionado, se a política não tivesse sido implementada, com os valores observados, foi estimada uma redução imediata de 3285 dispensações do medicamento e uma redução mensal de 1397 dispensações.

Por outro lado, pesquisas foram desenvolvidas buscando avaliar o efeito de uma intervenção no sistema de transporte. Um estudo conduzido por Fuller *et al.* (2011) teve como objetivo avaliar os efeitos de duas greves no metrô de Londres na 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 14699. Após a primeira greve, houve um aumento imediato de 3864 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 11263 viagens, seguido de uma redução para os valores vistos no período anterior às greves. Em relação a duração média das viagens, que era de 18,5 minutos, observou-se uma diminuição significativa de 20 minutos por dia no período pré-greve. Contudo, as greves não tiveram um efeito significativo na duração das viagens.

Borgatto (2000) desenvolveu um trabalho com a finalidade de analisar o comportamento do transporte urbano na cidade de São Paulo empregando a análise de séries temporais interrompidas. As séries analisadas foram número médio de passageiros por dia entre 1983 a 1998, número de assaltos nos ônibus urbanos entre 1992 a 1999 e número de acidentes de trânsito com os ônibus urbanos entre 1988 a 1999. Empregando a metodologia de Box e Jenkins, Borgatto (2000) 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 IBGE (2023). O sistema de transporte público da cidade é composto por ônibus, metrô, trem e barcas. Entre essas modalidades, o transporte por 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 (2023a).

A Secretaria Municipal de Transportes da cidade do Rio de Janeiro (doravante SMTR) é responsável por regulamentar e fiscalizar o sistema de transporte por ônibus, que é o enfoque deste estudo. A SMTR disponibiliza os dados relativos às operações de ônibus no município a partir do ano de 2015.

A seleção da cidade foi baseada na sua condição de centro urbano, a disponibilidade de informações nos sites eletrônicos oficiais, além do detalhamento dessas informações. A escolha pelo serviço de transporte público por ônibus foi motivada pelo seu papel significativo nos deslocamentos da população e por ser uma modalidade de transporte de grande representatividade no contexto do município.

3.1.1 Sistema de transporte público por ônibus do município do Rio de Janeiro

O sistema de transporte público por ônibus é operado por quatro consórcios: Intersul, Internorte, Transcarioca e Santa Cruz. Cada consórcio é responsável por uma zona geográfica da cidade, como indicado na Figura 4. O consórcio Intersul é constituído por 9 empresas, o Internorte por 14 empresas, o Transcarioca por 11 empresas e o Santa Cruz por 6 empresas, totalizando 29 empresas no sistema (RIO ÔNIBUS, 2024a). De acordo com a SMTR (2022), o sistema dispõe de uma frota total de 5.500 ônibus licenciados, dos quais 3.200 estão em operação.

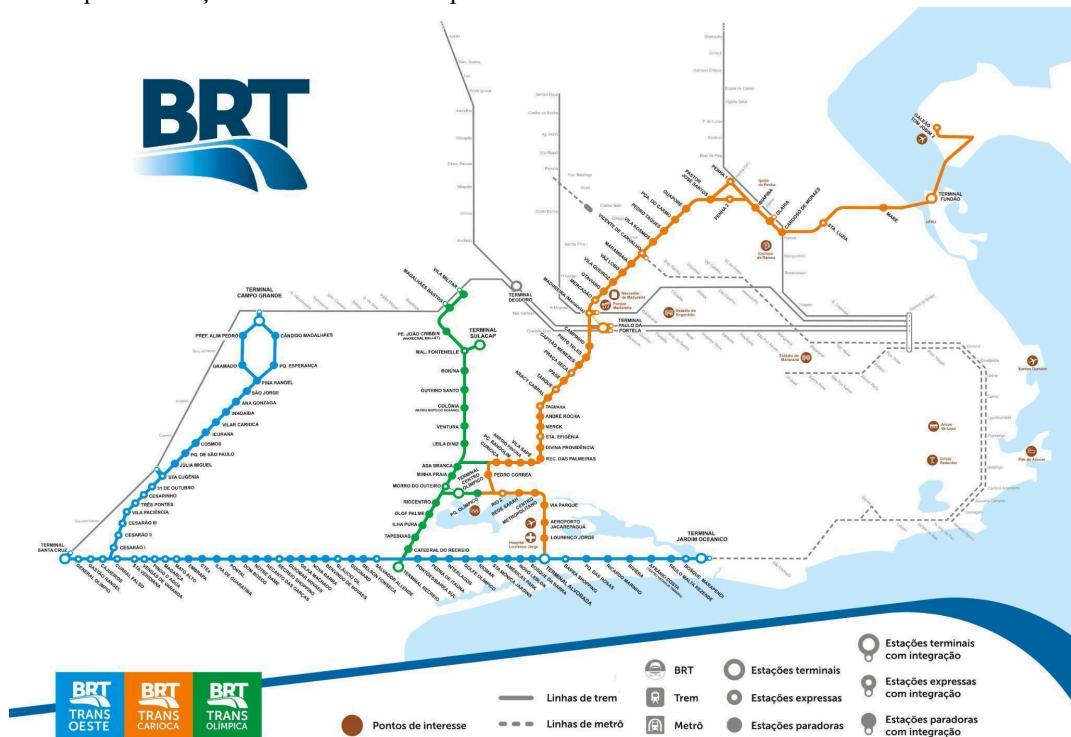
Figura 4 - Consórcios do sistema de transporte público por ônibus do município do Rio de Janeiro.



Fonte: Rio Ônibus (2024b)

Além disso, o sistema inclui o Acordo Operacional BRT, que corresponde ao sistema BRT(*Bus Rapid Transit*) operado em vias exclusivas para os ônibus. Esse sistema é estruturado em três corredores de tráfego: TransCarioca, TransOeste e TransOlímpica, conforme ilustrado na Figura 5. O sistema BRT se estende por 131,7 quilômetros, 124 estações operantes e 9 terminais (SMTR, 2023a).

Figura 5 - Mapa das estações de BRT do município do Rio de Janeiro



Fonte: Moovit (2023)

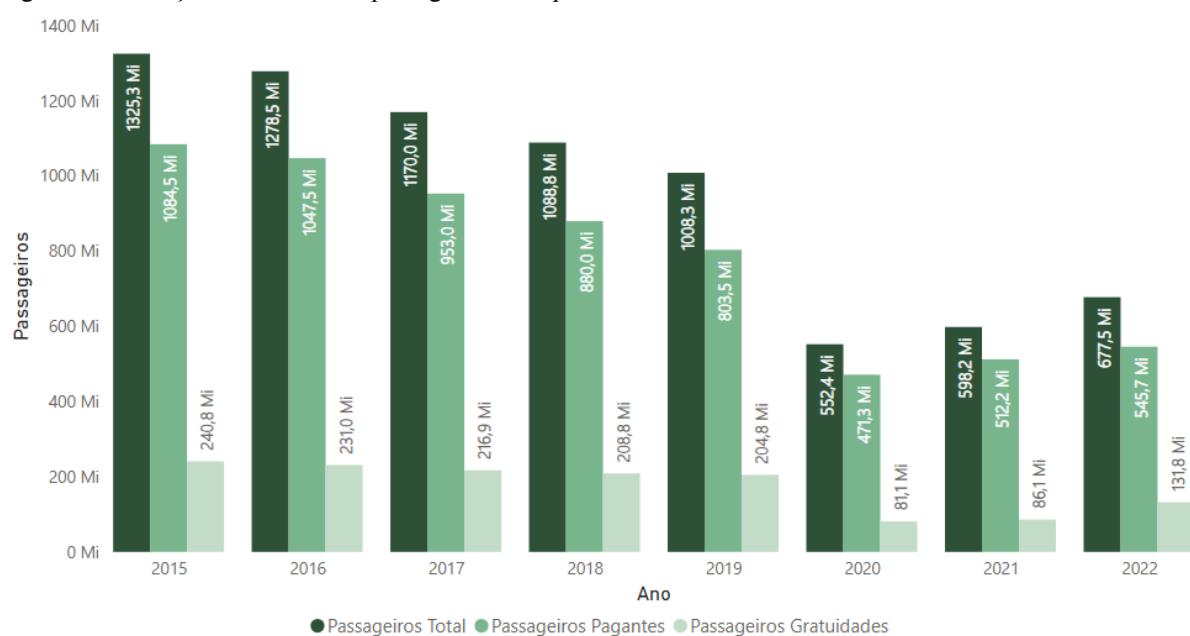
3.1.2 Desempenho operacional do sistema do transporte público por ônibus do município do Rio de Janeiro

Nessa seção serão apresentados alguns indicadores de desempenho operacional do transporte público por ônibus do município do Rio de Janeiro baseados nos dados disponibilizados pela SMTR.

3.1.2.1 Passageiros transportados

Passageiros total consiste na soma dos passageiros pagantes, também denominados passageiros equivalentes, e os passageiros que possuem gratuidade. As pessoas beneficiadas com a gratuidade incluem deficientes físicos, estudantes da rede municipal, estadual e federal de ensino, universitários beneficiados por programas federais, idosos e rodoviários. A Figura 6 apresenta a evolução dos passageiros transportados entre os anos de 2015 a 2022, na qual observa-se a redução dos passageiros ao longo dos últimos anos. O ano de 2020 registrou a maior queda no número de passageiros decorrente das medidas de distanciamento social adotadas para conter a disseminação da COVID-19 no país, com uma redução de mais de 45% em comparação ao ano de 2019.

Figura 6 - Evolução do número de passageiros transportados entre 2015 a 2022.

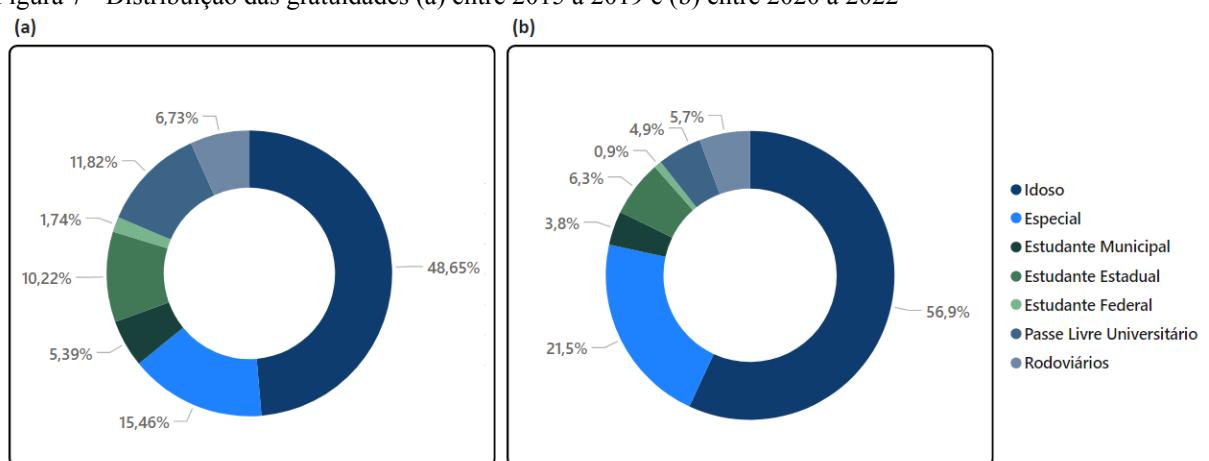


Fonte: Elaboração própria a partir de dados da SMTR.

Entre 2015 a 2019, os idosos e deficientes representavam a maior proporção de usuários que se beneficiam da gratuidade, seguidos pelos universitários e estudantes da rede estadual de ensino. A Figura 7 apresenta a distribuição das gratuidades do período de 2015 a

2019 e de 2020 a 2022. Observa-se que houve uma redução de 85,22% no número de estudantes, principalmente dos universitários, entre os anos de 2020 a 2022, o que pode ser associado à adoção do ensino remoto. Além disso, evidenciou-se uma diminuição mais significativa na demanda com gratuidade durante o período pandêmico. Enquanto o número de passageiros pagantes reduziu 67,93%, o número de passageiros com gratuidades reduziu 72,88%. Isso pode ser associado ao decrescimento da circulação dos idosos por serem considerados do grupo de risco para agravamento da doença, assim como pela adoção do ensino remoto nas escolas e universidades.

Figura 7 - Distribuição das gratuidades (a) entre 2015 a 2019 e (b) entre 2020 a 2022



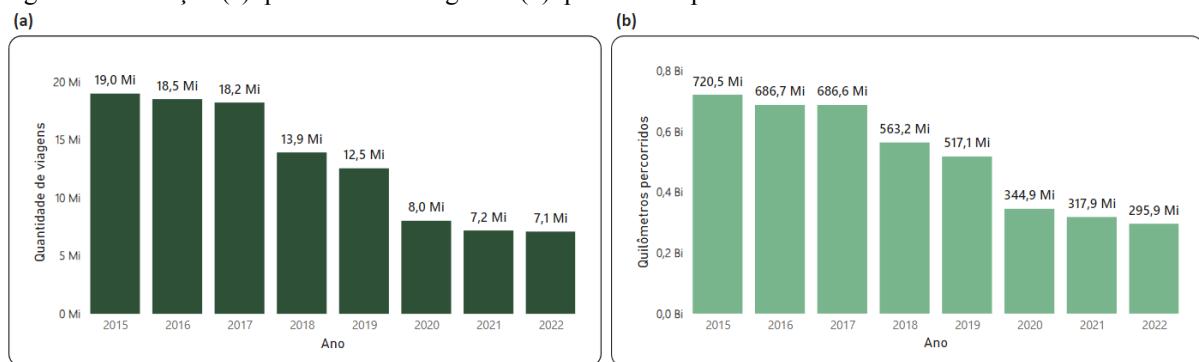
Fonte: Elaboração própria a partir de dados da SMTR.

3.1.2.2 Viagens realizadas e quilometragem percorridos

Nos últimos anos, a oferta do serviço reduziu substancialmente, conforme pode ser visto na Figura 8, que ilustra o número de viagens realizadas e quilômetros percorridos de 2015 até 2022. Em 2018, a redução da oferta foi consideravelmente maior quando comparada a dos anos anteriores, com uma diminuição de 23,61% da quantidade de viagens e de 17,98% dos quilômetros percorridos.

A partir de março de 2020, com o fechamento parcial do comércio, serviços, indústrias e escolas, houve uma diminuição significativa na circulação de pessoas, consequentemente o nível de oferta do serviço foi reduzido. Assim sendo, ocorreu uma queda de aproximadamente 36% no número de viagens e 33% na quilometragem percorrida em 2020 quando comparado ao ano de 2019.

Figura 8 - Evolução (a) quantidade de viagens e (b) quilômetros percorridos entre 2015 e 2022.



Fonte: Elaboração própria a partir de dados da SMTR.

3.1.2.3 Índice de passageiros por quilômetro (IPK) e índice de passageiros equivalentes por quilômetro (IPKe)

O índice de passageiros equivalentes por quilômetro (IPKe) corresponde ao número de passageiros equivalentes transportados por quilômetro percorrido, sendo considerado um indicador para avaliar a produtividade do serviço de transporte público por ônibus. Contudo, é relevante complementar sua análise com a avaliação das variáveis que compõem seu cálculo.

A evolução do indicador entre os anos de 2015 a 2022, apresentado na Figura 9, revela comportamentos distintos ao longo desse período. Em 2017, o IPKe sofreu uma queda de 9%, reflexo da diminuição do número de passageiros equivalentes e da manutenção da quilometragem percorrida, resultando na redução do indicador, ou seja, em um menor número de pessoas transportadas por quilômetro percorrido. Todavia, nos anos de 2021 e 2022, foi observado o fenômeno inverso, aumento da demanda e redução da oferta, resultando no aumento do indicador, isto é, um aumento de passageiros por quilômetro percorrido. Contudo, considerando a emergência de saúde pública, esse cenário pode indicar um baixo nível do serviço ao invés de uma melhora da produtividade do sistema, ocasionando uma possível diminuição na qualidade do serviço prestado. Em 2020, o IPKe registrou o menor valor nos últimos oito anos, apresentando uma redução de 13,5% em relação ao ano de 2019. Esse declínio foi decorrente da diminuição tanto da demanda quanto da oferta do serviço, impactadas pela pandemia de COVID-19.

O índice de passageiros por quilômetro, apresentado na Figura 9, corresponde aos passageiros equivalentes e com gratuidades transportados por quilômetro. Esse indicador apresenta um desempenho similar ao do índice de passageiros equivalentes por quilômetro ao decorrer dos anos de 2015 a 2019. A partir de 2020, o indicador acompanha as variações, porém em percentuais diferentes. Em 2020, a redução desse índice foi mais acentuada, pois o número de passageiros com gratuidades utilizando o transporte público por ônibus reduziu.

Por outro lado, em 2022, com o retorno consolidado das atividades em escolas e universidades, houve um aumento dos estudantes e universitários nos ônibus.

Figura 9 - Evolução do índice de passageiros por quilômetro e do índice de passageiros equivalentes por quilômetro entre 2015 a 2022.



Fonte: Elaboração própria a partir de dados da SMTR.

3.2 COLETA DOS DADOS

A coleta dos dados para esta pesquisa envolveu a obtenção de informações relacionadas à operação de ônibus, ao volume de tráfego, à composição da frota de veículos, despesas com transporte e ao impacto da pandemia no mercado de trabalho no município do Rio de Janeiro. Esta etapa de coleta foi realizada através da consulta a portais eletrônicos oficiais de instituições a níveis municipal, estadual e federal.

Os dados relativos à operação dos ônibus foram adquiridos através do site da Secretaria Municipal de Transporte do Rio de Janeiro nas primeiras quinzenas de outubro de 2022 e fevereiro de 2023. Foram coletadas informações como o número de passageiros transportados, incluindo pagantes e gratuidades, a quantidade de viagens realizadas, a quantidade de quilômetros percorridos, e o índice de passageiros por quilômetro. A SMTR disponibiliza esses dados em painéis interativos, que permitiram o acesso e a tabulação subsequente em planilhas eletrônicas.

Foram feitas solicitações de acesso à informação aos dados da operação dos ônibus na Central de Atendimento 1746 e no Sistema Eletrônico de Informação ao Cidadão (e-SIC.RJ), visando obter um dataset do órgão responsável. A Central de Atendimento 1746 forneceu o endereço eletrônico que foi utilizado para fazer a extração manual dos dados. O e-SIC, por sua vez, informou que as informações estariam disponíveis no Boletim de

Mobilidade Urbana, que só continha dados a partir de abril de 2021, não atendendo completamente ao escopo deste trabalho.

A Companhia de Engenharia de Tráfego do Rio de Janeiro (doravante CET-Rio) disponibiliza relatórios contendo informações sobre o fluxo de tráfego na cidade. Estes relatórios apresentam o Indicador Global de Volume Veicular (IGVOL), decorrente da média mensal de tráfego dos principais pontos de corredores estruturais e arteriais, conforme a classificação viária adotada pela CET-Rio. Os relatórios foram acessados no site da CET-Rio nas primeiras quinzenas de outubro de 2022 e março de 2023, sendo os dados extraídos de arquivos em formato PDF e posteriormente tabulados em planilhas eletrônicas.

Informações referentes à frota de automóveis e motocicletas no município foram coletadas no portal do Departamento de Trânsito do Estado do Rio de Janeiro (doravante DETRAN-RJ) na primeira quinzena de janeiro de 2023. Estes dados foram igualmente tabulados em uma planilha eletrônica.

A Pesquisa de Orçamentos Familiares, realizada pelo IBGE, disponibiliza informações sobre a distribuição dos gastos mensais por tipo de despesas conforme os grupos socioeconômicos. Os gastos relacionados ao transporte englobam despesas com transporte urbano, combustíveis, como gasolina e álcool, manutenção e aquisição de veículos, entre outras. Os resultados dessa pesquisa foram consultados em tabelas disponibilizadas pelo IBGE na primeira quinzena de dezembro de 2023.

As informações referentes ao impacto da pandemia no mercado de trabalho foram obtidas através de duas pesquisas realizadas pelo Instituto Brasileiro de Geografia e Estatística. A Pesquisa Nacional por Amostra de Domicílios - PNAD COVID-19, que abordou questões sobre afastamento do trabalho e prática do trabalho remoto durante a pandemia, abrangendo o período de maio a novembro de 2020, e a Pesquisa Nacional por Amostra de Domicílios Contínua - PNAD Contínua, que a partir do 4º trimestre de 2022 incluiu um módulo sobre teletrabalho. Os resultados da PNAD COVID-19 foram obtidos na primeira quinzena de fevereiro de 2023 e da PNAD Contínua na segunda quinzena de outubro de 2023 em planilhas no site eletrônico do IBGE.

A Tabela 1 apresenta os endereços eletrônicos nos quais os dados descritos estão disponíveis.

Tabela 1 - Endereço eletrônico dos dados coletados.

Base de dado	Endereço eletrônico
Operação dos ônibus	https://transportes.prefeitura.rio/informacao-da-operacao-dos-onibus-1/
IGVOL	https://cetrio.prefeitura.rio/diretoria-de-engenharia-de-trafego/
Frota por tipo de veículo	https://www.detran.rj.gov.br/_estatisticas.veiculos/index.asp
Pesquisa de Orçamentos Familiares	https://sidra.ibge.gov.br/pesquisa/pof/tabelas
PNAD COVID-19	https://www.ibge.gov.br/estatisticas/sociais/trabalho/27947-divulgacao-mensal-pnadcovid2.html?=&t=resultados
PNAD Contínua	https://sidra.ibge.gov.br/pesquisa/pnadca/tabelas

Fonte: Elaboração própria.

Inicialmente, a coleta dos dados envolveu pesquisas dos conjuntos de dados disponíveis. Contudo, os dados relacionados à operação dos ônibus, fluxo de veículos e frota de veículos não eram disponibilizados em datasets. Em decorrência dessa limitação, foi necessário realizar a extração manual e a subsequente tabulação dos dados, adicionando complexidade ao processo de coleta. Utilizou-se o *software* Microsoft Excel para a tabulação, enquanto o *software* Tableau Prep foi empregado no tratamento das informações coletadas.

3.3 FERRAMENTAS DE ANÁLISE DOS DADOS

3.3.1 Séries temporais interrompidas

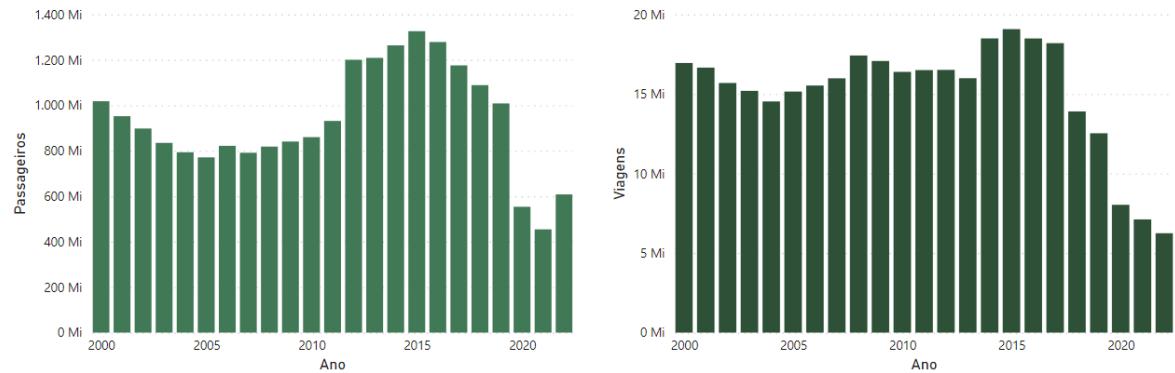
As séries temporais analisadas foram o número de passageiros transportados, incluindo pagantes e gratuitades, e a quantidade de viagens realizadas no sistema de transporte público no município do Rio de Janeiro. Estas séries compreendem um total de 96 meses, desde janeiro de 2015 até dezembro de 2022. O mês de março de 2020 foi definido como o instante da intervenção, pois nesse mês foram implementadas as medidas de distanciamento social no município, resultando na redução da circulação de pessoas. Com isso, foram definidos dois períodos para a modelagem da série: o período pré-pandemia com 62 observações, entre janeiro de 2015 a fevereiro de 2020, e o período pós-pandemia com 34 observações, entre março de 2020 a dezembro de 2022.

É necessário possuir pontos antes e depois da intervenção para a modelagem de séries temporais interrompidas usando regressão segmentada, contudo Bernal *et al.* (2017) afirmam que não há um número específico de pontos, pois o poder estatístico depende de outros fatores como a variabilidade dos dados, a amplitude do efeito e a variação sazonal. Por outro lado, Wagner *et al.* (2002) sugere que 24 pontos possibilita avaliar adequadamente a variação sazonal para uma série temporal com a unidade de tempo mensal, e que 100 observações é uma quantidade mínima necessária para obter um nível aceitável de variabilidade na estimativa de cada ponto no tempo.

Nesse sentido, Linden *et al.* (2003) e Wagner *et al.* (2002) afirmam que para empregar modelos ARIMA é necessário no mínimo 50 observações. Além disso, é recomendado pelo menos 4 anos de observação anteriores ao mês que foi implementada a intervenção, pois isso permitirá que o modelo acomode padrões subjacentes que possam interferir no ajuste dos parâmetros do modelo (LINDEN *et al.*, 2003).

Acrescenta-se que a potência estatística aumenta com o número de observações no tempo, contudo não é mais adequado ter mais pontos quando as tendências históricas variam substancialmente, pois isso não forneceria uma representação precisa das tendências atuais contidas na série (ROBINSON; HARRIS, 2009 apud BERNAL et al., 2017). Os dados da operação dos ônibus fornecidos pela SMTR estão disponíveis apenas a partir de janeiro de 2015, por isso não foi possível obter dados mensais anteriores a esse ano. Entretanto, ao observar as séries temporais do número de passageiros transportados e da quantidade de viagens realizadas por ano fornecidas pelo Data.Rio(2023b) na Figura 10, fica evidente a mudança na tendência a partir do ano de 2015 em ambas as séries. Portanto, utilizar dados anteriores a 2015 poderia prejudicar na identificação da tendência antes da intervenção e, consequentemente, interferir na análise do impacto da intervenção.

Figura 10 - Evolução do número de passageiros transportados e quantidade de viagens realizadas entre 2000 a 2022.



Fonte: Elaboração própria a partir de dados do Data.Rio.

Além disso, as observações do segmento pré-intervenção abrangem 62 meses e do segmento pós-intervenção abrangem 34 meses, permitindo o ajuste dos componentes da série e a avaliação da extensão do efeito da pandemia na demanda do transporte público.

3.3.2 Aplicação do modelo de regressão segmentada

Um procedimento composto por cinco passos para a implementação da regressão segmentada na análise de séries temporais interrompidas foi descrito por Bernal et al. (2017). O primeiro passo consiste em avaliar se o modelo de séries temporais interrompidas é apropriado para o propósito do estudo. Nesse sentido, três requisitos devem ser considerados: definição precisa do ponto de intervenção, com uma clara demarcação do período anterior e posterior à intervenção; observação de uma mudança imediata na variável resposta após a implementação da intervenção ou após um atraso claramente definido; e disponibilidade de observações tanto antes quanto depois da intervenção, acompanhada de uma avaliação da qualidade dos dados em termos de validade e confiabilidade. As séries temporais analisadas neste estudo atendem aos três requisitos. O ponto de intervenção foi definido em março de 2020, dividindo o período pré-intervenção, com 62 observações, e pós-intervenção, com 34 observações. Além disso, observou-se o efeito imediato da implementação das medidas restritivas neste mês.

O segundo passo consiste na formulação do efeito da intervenção na série temporal, avaliando se houve uma mudança de nível imediata ou em um período posterior à intervenção, além de analisar se a tendência da série sofreu uma alteração gradual após a intervenção.

O terceiro passo consiste em uma análise descritiva dos dados, incluindo a elaboração de um gráfico da série temporal, que auxilia na identificação de tendência, sazonalidade e valores atípicos. Também recomendam comparações entre o período anterior e posterior à intervenção. Desta forma, foram elaborados gráficos das séries temporais e tabelas com a variação anual e as medidas estatísticas de cada período das séries, permitindo observar as características das séries antes e após a intervenção e o efeito da intervenção.

O quarto passo abrange o ajuste do modelo de regressão. Com base na Equação 1 apresentada, foram definidas as variáveis do modelo. A variável "Tempo", que reflete a evolução sequencial dos meses na série temporal, a variável "Pandemia", a qual assume o valor 0 para os meses anteriores à intervenção e o valor de 1 para os meses posteriores ao seu início, e a variável "Tempo pós-pandemia", que recebe o valor 0 para o período pré-intervenção e, a partir do momento da intervenção, recebe valores sequenciais a partir de 1. Utilizou-se o modelo linear generalizado de Poisson, recomendado quando a variável dependente representa dados de contagens.

O quinto passo aborda o tratamento das questões metodológicas relacionadas às séries temporais, uma vez que essas séries apresentam características distintas que exigem abordagens específicas para aprimorar a robustez da análise. Dentre essas considerações metodológicas, destacam-se: sazonalidade, autocorrelação, superdispersão, variáveis de confusão, uso de grupo de controle.

Os modelos de regressão possuem alguns pressupostos que são apresentados por Hyndman e Athanasopoulos (2018), conforme exposto abaixo:

- O modelo é linear nos parâmetros, ou seja, a relação entre a variável dependente e as variáveis independentes segue uma equação linear;
- Os erros têm média igual a zero;
- Os erros têm variância constante, conhecida como homocedasticidade dos resíduos;
- Os erros não são autocorrelacionados;
- Os erros são normalmente distribuídos;
- Os erros não têm relação com as variáveis independentes.

Após ajustar o modelo de regressão segmentada, foram gerados gráficos dos resíduos para verificar se as suposições do modelo foram atendidas. O resíduo é a diferença entre os valores observados e os valores previstos pelo modelo, isto é, os erros do modelo. Além disso, para verificar a autocorrelação dos valores residuais foi realizado o teste estatístico DW de Durbin-Watson. Os estatísticos tabularam os limites inferiores, dL, e os limites superiores, dU

para vários valores de tamanho de amostra e número de variáveis explicativas. A representação gráfica da estatística DW, na Figura 11, mostra que os valores podem variar de 0 a 4, sendo que valores próximos a 2 indicam ausência de correlação, valores maiores que 2 indicam uma correlação negativa e valores menores que 2 indicam uma correlação positiva (SOBRAL E ROCHA, 2019). Investigando a possibilidade de uma autocorrelação positiva, considera-se que se $d_U < DW$ não existe correlação serial, se $DW < d_L$ indica a presença de correlação positiva e se $d_L < DW < d_U$ o teste é inconclusivo. Enquanto investigando a possibilidade de uma correlação negativa, considera-se que se $DW < 4 - d_U$ não existe correlação, se $DW > 4 - d_L$ indica a presença de correlação negativa e se $4-d_U < DW < 4-d_L$ o teste é inconclusivo.

Figura 11 - Teste de Durbin-Watson para correlação dos resíduos.



Fonte: Fávero e Belfiore (2017) apud Pereira, G *et al.* (2021)

As etapas do procedimento descrito foram realizadas com auxílio do Google Collaboratory utilizando a linguagem Python.

3.3.3 Aplicação do modelo ARIMA

Uma intervenção pode impactar uma série temporal, alterando o nível ou a inclinação da série normalmente, contudo a tendência, a sazonalidade e o erro aleatório são três componentes da série que podem se confundir com o efeito da intervenção (MORETTIN; TOLOI, 2006). Os modelos SARIMA consideram esses três elementos na modelagem da série e portanto são capazes de descrever o comportamento dessas séries.

A análise de séries temporais interrompidas utilizando o modelo ARIMA pode ser conduzida seguindo quatro etapas, conforme proposto por Schaffer *et al.* (2021). A primeira etapa consiste na representação gráfica dos dados, visando a identificação dos padrões, como tendência e sazonalidade, e observações atípicas. Nesse sentido, o gráfico de decomposição das séries temporais foi utilizado para evidenciar esses três componentes. Adicionalmente, foi

traçado um gráfico de sazonalidade, no qual a série é dividida pelos meses e a média de cada mês é representada por um traço.

Na segunda etapa, é realizada a verificação da estacionariedade da série, sendo aplicadas transformações por diferenciação para estabilizar a variância caso a série não seja estacionária. Diversas ferramentas podem ser empregadas para essa análise, como a construção de gráficos de linha e das funções de autocorrelação e autocorrelação parcial. Todavia, Silveira *et al.* (2022) ressaltam que a interpretação desses gráficos requer experiência do analista. Nesse sentido, os autores afirmam que vários procedimentos apresentam melhor desempenho na identificação da presença de raiz unitária em uma série temporal, como o teste de Dickey-Fuller Aumentado, no qual a hipótese nula é de que há presença de raiz unitária e a hipótese alternativa é de que não há presença de raiz unitária, sendo assim a série temporal pode ser considerada estacionária.

A terceira etapa engloba a seleção do modelo. A identificação dos parâmetros do modelo pode ser feita de duas formas, através de algoritmos automatizados ou com base na análise dos gráficos da função de autocorrelação (ACF) e da função de autocorrelação parcial (PACF). A seleção dos parâmetros do modelo é considerada subjetiva e difícil de aplicar para muitas pessoas, contudo nos últimos 25 anos foram desenvolvidas várias tentativas para automatizar essa etapa, como destacado Hyndman e Khandakar (2008). Entre essas soluções automatizadas, o pacote forecast, escrito pelos autores na linguagem de programação R, se destaca, pois oferece uma função denominada `auto.arima`, que realiza o ajuste automático do modelo ARIMA. Segundo os autores, essa função indica o modelo mais adequado com base na minimização do critério de informação Akaike Information Criteria (AIC), calculado conforme a Equação 6, na qual L é a função de verossimilhança do modelo ajustado e $k = 1$ se $c \neq 0$ e $k = 0$ se $c = 0$. A minimização do critério de informação Bayesian Information Criteria (BIC) também é útil para selecionar bons modelos, sendo calculado conforme a Equação 7 (HYNDMAN; ATHANASOPOULOS, 2018).

$$AIC = -2 \log(L) + 2(p + q + P + Q + k) \quad (6)$$

$$BIC = AIC + [\log(T) - 2](p + q + k + 1) \quad (7)$$

A fase de identificação do modelo também envolveu a análise do efeito da intervenção. Acrescentou-se ao modelo as variáveis “nível” e “rampa” como variáveis exógenas. 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 após a intervenção. 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 identificação do modelo foi realizada de forma automatizada por meio da função *auto.arima*.

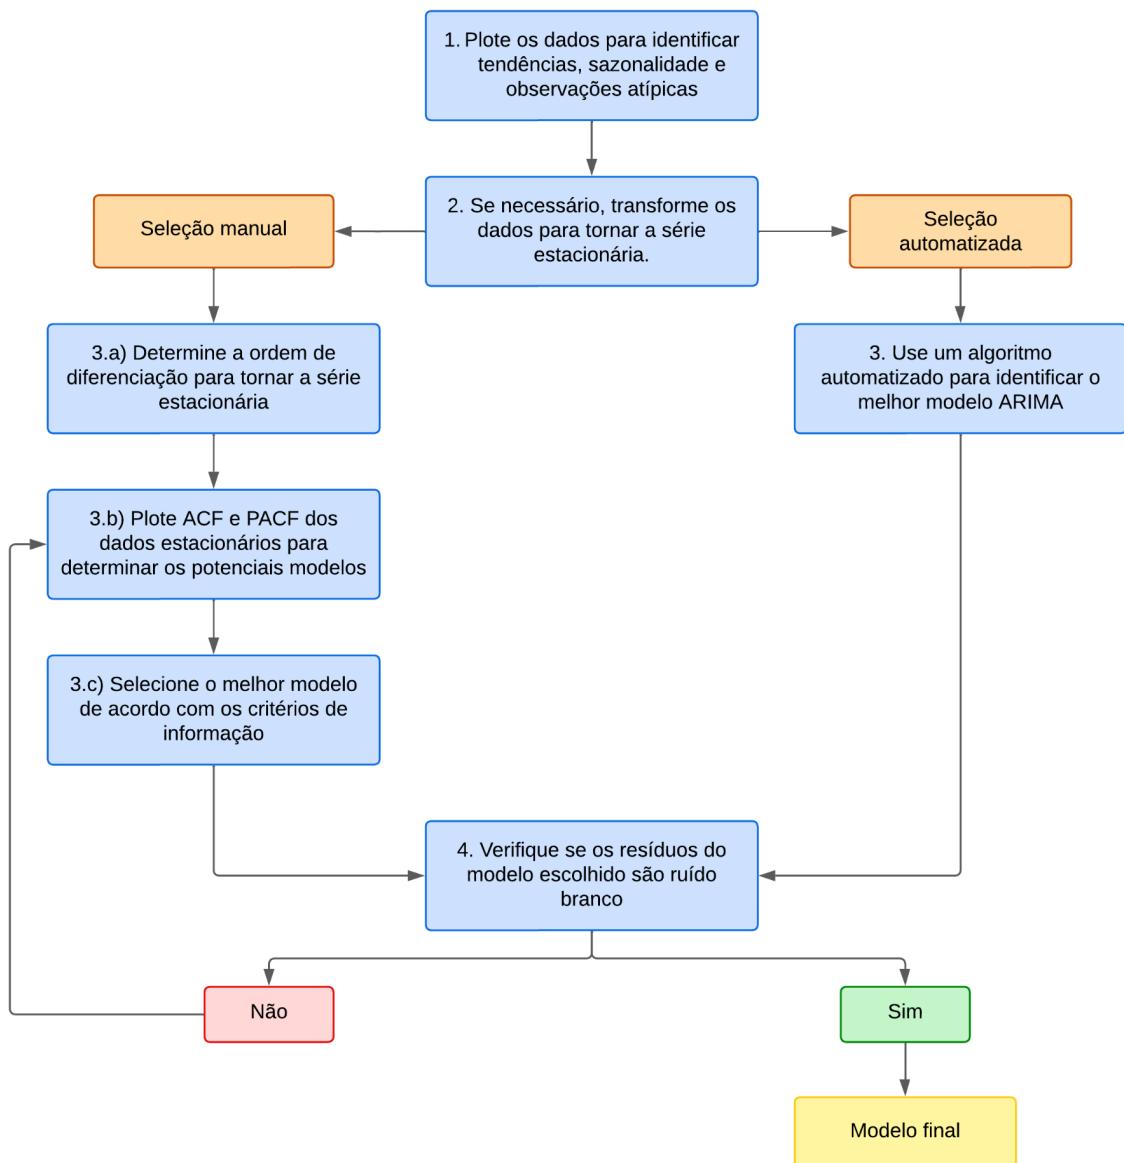
A quarta etapa consiste na verificação se os resíduos se comportam como ruído branco, ou seja, não são autocorrelacionados. Essa verificação pode ser feita através da análise dos gráficos de resíduos. Além disso, o teste de Ljung-Box foi aplicado para testar a presença de autocorrelação nos resíduos. No teste proposto por Ljung e Box, a hipótese nula é de não existir evidências de autocorrelação nos resíduos, enquanto a hipótese alternativa é de ter evidências de autocorrelação nos resíduos (PEREIRA, T *et al.*, 2021).

Se os resíduos apresentarem autocorrelação ou não apresentarem uma distribuição normal, ou seja, seu comportamento não ser um ruído branco, é necessário retornar a terceira etapa e selecionar outro modelo. Schaffer *et al.* (2021) também explicam que a determinação dos parâmetros do modelo é um processo iterativo que envolve tentativa e erro, com a finalidade de selecionar o modelo que tenha um bom ajuste e controle adequado da autocorrelação e sazonalidade, buscando a minimização do número de parâmetros.

Após a seleção do modelo, foi possível estimar o impacto da intervenção nas séries. O modelo selecionado foi utilizado para prever o comportamento das séries caso a pandemia não tivesse ocorrido, conhecido como cenário contrafactual.

As etapas acima descritas são ilustradas na Figura 12. Todas as etapas foram realizadas com auxílio do Google Collaboratory utilizando a linguagem R.

Figura 12 - Procedimento para a seleção do modelo ARIMA.



Fonte: Adaptado de Hyndman e Athanasopoulos (2018)

3.3.4 Avaliação do modelo

A avaliação da precisão de um modelo na representação de um conjunto de dados é feita através dos erros de previsão. De acordo com Makridakis *et al.* (1998, p.42-43), a precisão da previsão desempenha um papel fundamental na escolha de um modelo, uma vez que está diretamente relacionada à capacidade do modelo de reproduzir de forma acurada os dados.

Para a avaliação da qualidade dos modelos, foram utilizadas as seguintes métricas: erro médio absoluto (MAE), raiz do erro médio quadrático (RMSE) e erro percentual médio absoluto (MAPE). Considerando que Y_t é a observação real para o período de tempo t e \hat{Y}_t é a previsão para o mesmo período, esses métricas são expressas da seguinte forma.

O erro absoluto médio (MAE) corresponde a soma dos erros absolutos dos n períodos dividida pelo número de períodos, dado pela Equação 8.

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (8)$$

O erro quadrático médio (MSE) consiste na soma dos quadrados dos erros dos n períodos dividida pelo número de períodos. A raiz quadrada do erro quadrático médio (RMSE) é a raiz quadrada do erro quadrático médio, demonstrado na Equação 9.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (9)$$

O erro percentual médio absoluto (MAPE), representa a média percentual entre os erros absolutos e a observação real, dado pela Equação 10.

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \right) \cdot 100 \quad (10)$$

3.3.5 Análise exploratória

A análise exploratória visa resumir e organizar os dados coletados através de tabelas, gráficos e medidas numéricas e, a partir dos dados resumidos, identificar possíveis padrões ou regularidades nas observações (REIS, 2008). Com esse intuito, aplicou-se técnicas estatísticas descritivas e construiu-se representações gráficas utilizando as ferramentas Tableau e Power BI. Essas abordagens foram utilizadas com o intuito de compreender o comportamento geral dos dados, identificar possíveis valores discrepantes, descrever as principais características das variáveis, examinar o impacto da pandemia de COVID-19 e investigar as relações entre elas, assim como a relação com o efeito pandêmico.

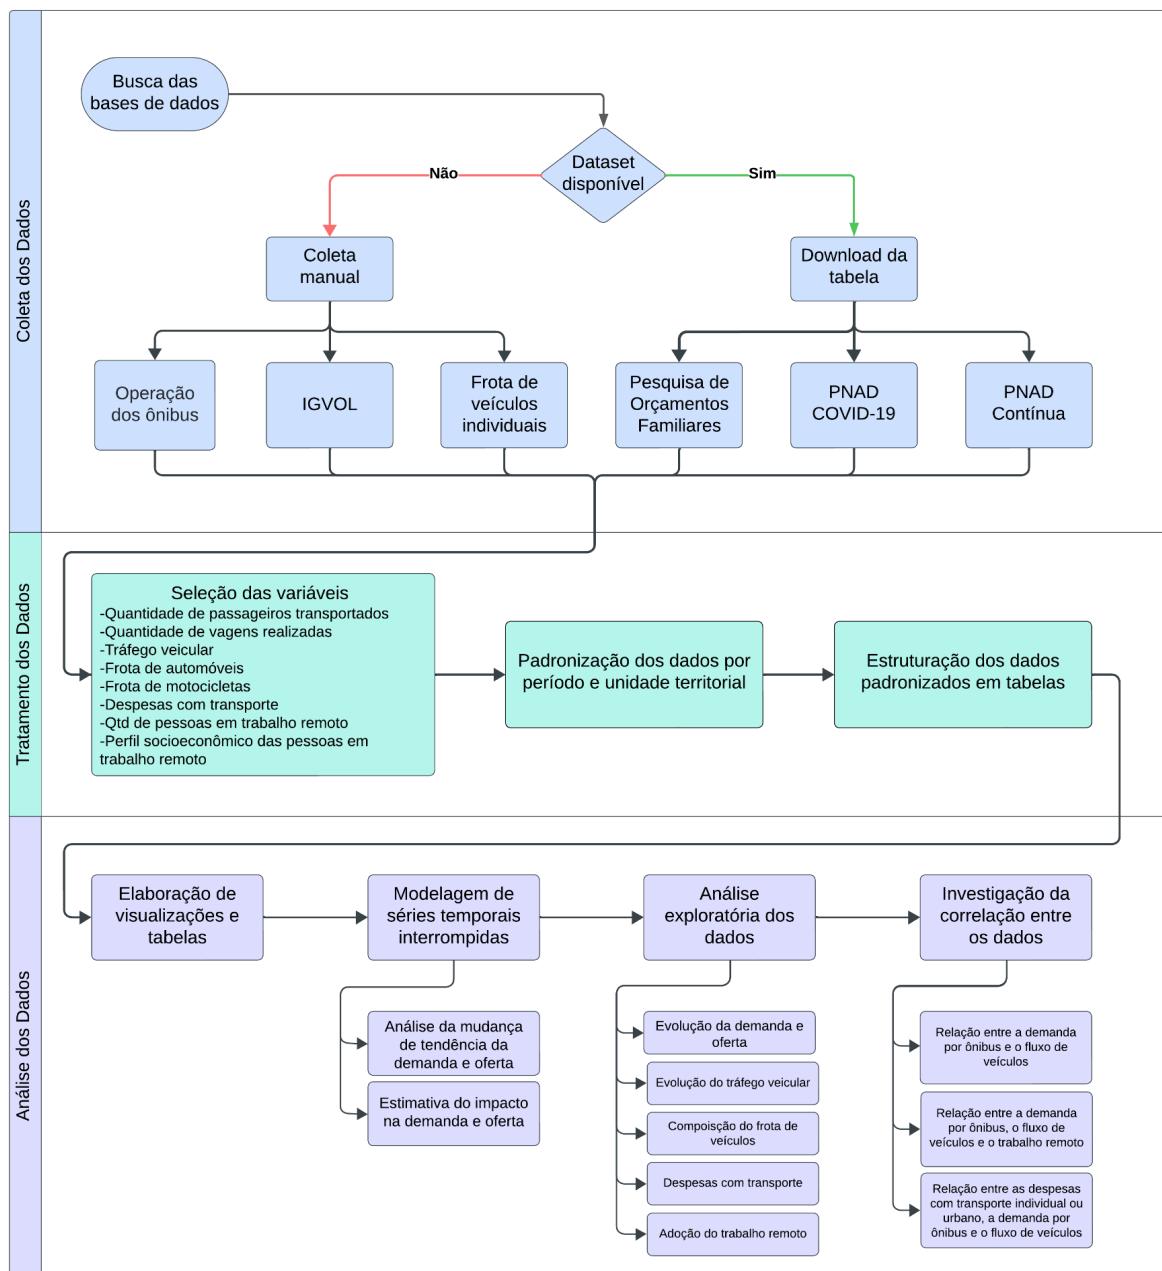
A divisão temporal estabelecida em março de 2020 serviu como referência para distinguir o período pré-pandêmico do pós-pandêmico, possibilitando a análise comparativa do comportamento das variáveis nessas diferentes fases. Construiu-se tabelas com os valores anuais das variáveis para avaliar sua evolução e sua variação ao longo dos anos, assim como

visuais com a evolução mensal das variáveis. Procurou-se analisar o mesmo período de tempo para todas as variáveis, mas indisponibilidade de dados isso não foi possível.

Com relação ao trabalho remoto, a análise concentrou-se na proporção de pessoas que adotaram essa prática, examinando seus perfis e tipos de ocupação. A comparação entre os resultados das pesquisas PNAD COVID-19 e Continua buscou investigar se o trabalho remoto permaneceu uma escolha prevalente e se o perfil dessas pessoas manteve-se o mesmo do início da pandemia. Além disso, explorou-se a possível correlação entre a prática do trabalho remoto e a demanda pelo transporte público, bem como o impacto resultante no tráfego de veículos.

O fluxograma representado na Figura 13 ilustra a sequência das etapas do processo metodológico adotado neste estudo. O processo foi iniciado com a coleta dos dados públicos, constituindo a primeira etapa da pesquisa. Posteriormente, na etapa de tratamento de dados, ocorreu a seleção de variáveis alinhadas aos objetivos estabelecidos, seguida pela padronização dos dados até a formação das bases de dados finais. Por fim, na terceira etapa, a análise dos dados foi conduzida através da modelagem de séries temporais interrompidas, e por meio da análise exploratória com o auxílio de gráficos e tabelas.

Figura 13 - Fluxograma do procedimento metodológico.



Fonte: Elaboração própria.

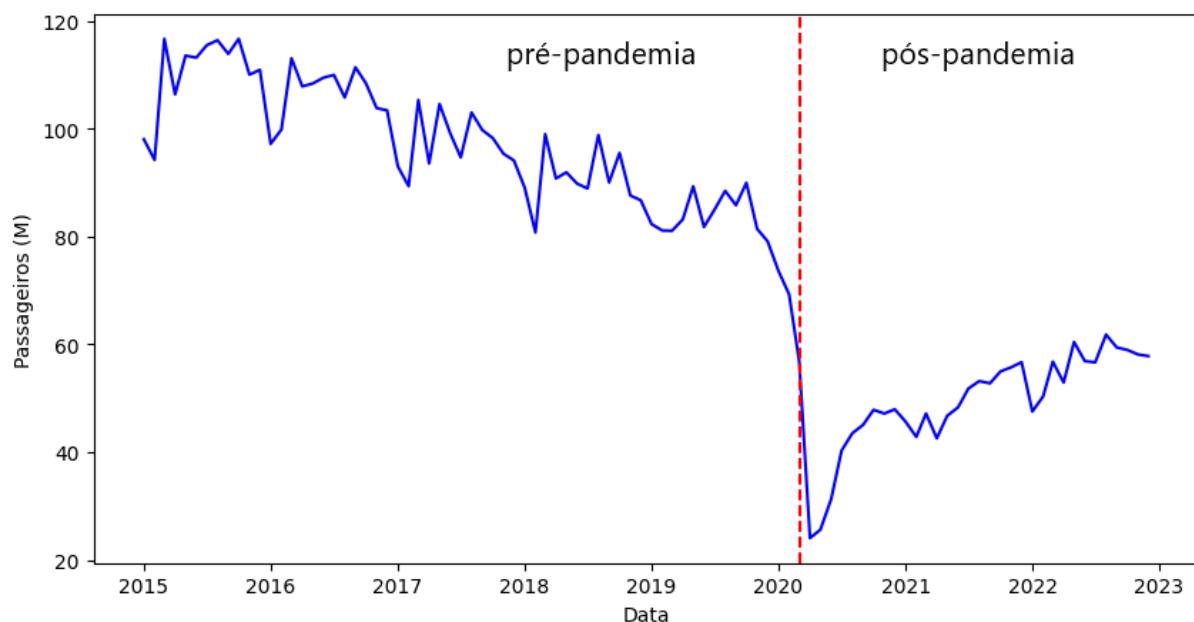
A análise dos dados utilizando as duas abordagens metodológicas, possibilitou avaliar o impacto da pandemia no transporte público por ônibus, assim como avaliar as mudanças no padrão de deslocamentos decorrentes do contexto pandêmico.

4 RESULTADOS E DISCUSSÃO

4.1 QUANTIDADE DE PASSAGEIROS TRANSPORTADOS

A série temporal da quantidade de passageiros transportados no sistema de transporte público por ônibus abrangendo os meses de janeiro de 2015 a dezembro de 2022 é ilustrada na Figura 14. Evidencia-se a diminuição na demanda nos últimos anos, agravada pela acentuada redução com o surgimento da pandemia de COVID-19. Em abril de 2020, foi registrada uma queda abrupta de mais de 57% no número de passageiros em relação ao mês anterior, atribuída às medidas de restrição de circulação de pessoas implementadas com o objetivo de conter a disseminação do vírus. No período pré-pandemia, a média mensal de passageiros transportados foi 97 milhões, enquanto no período pós-pandemia essa média diminuiu para cerca de 50 milhões de passageiros.

Figura 14 - Série temporal do número de passageiros transportados.



Fonte: Elaboração própria a partir de dados da SMTR.

A Tabela 2 apresenta o número de passageiros transportados e a variação percentual em relação ao ano anterior entre os anos de 2015 a 2022. Observa-se que entre 2015 e 2019 houve uma redução gradual da demanda, com uma diminuição de 23,9% no número de passageiros no ano de 2019 quando comparado ao ano de 2015. Em 2020, ocorreu uma perda de mais de 45,2% de usuários em relação ao ano anterior devido aos impactos da pandemia. Nos anos seguintes, 2021 e 2022, verifica-se uma pequena recuperação da demanda, porém sem atingir os valores observados nos anos anteriores à crise sanitária.

Tabela 2 - Número de passageiros transportados e variação percentual.

Ano	Passageiros (M)	Variação percentual (%)
2015	1325,30	
2016	1278,51	-3,53
2017	1169,96	-8,49
2018	1088,78	-6,94
2019	1008,33	-7,39
2020	552,43	-45,21
2021	598,25	8,29
2022	677,52	13,25

Fonte: Elaboração própria a partir de dados da SMTR.

As estatísticas descritivas da série no período pré-pandemia e pós-pandemia são exibidas na Tabela 3. Observa-se que a média de passageiros no período pandêmico reduziu 48,9% em comparação ao período anterior. Além disso, houve uma redução do desvio padrão, indicando uma menor dispersão no número de passageiros durante a pandemia. Adicionalmente, a assimetria mais acentuada no período pós-pandemia sugere uma distribuição mais inclinada para números menores de passageiros. Já o aumento da curtose aponta uma distribuição dos dados com extremidades mais acentuadas no período pós-pandemia, refletindo uma maior ocorrência de valores atípicos em relação ao período pré-pandemia.

Tabela 3 - Estatísticas descritivas do número de passageiros transportados.

Estatísticas	Pré-pandemia	Pós-pandemia
Média	97,00	49,57
Desvio padrão	11,80	9,08
Mínimo	69,26	24,05
1º Quartil	88,94	45,92
Mediana	96,33	51,06
3º Quartil	107,48	56,74
Máximo	116,66	61,80
Assimetria	-0,08	-1,23
Curtose	-0,84	1,54

Fonte: Elaboração própria a partir de dados da SMTR.

Os meses de menor volume de passageiros foram fevereiro de 2020 e abril de 2020, enquanto outubro de 2015 e agosto de 2022 registraram a maior demanda, nos períodos pré e pós pandemia respectivamente. A comparação entre os quartis e as medidas de centralidade antes e depois da pandemia demonstraram uma queda superior a 47%, evidenciado o grande impacto sofrido na demanda do transporte público por ônibus com a redução de circulação das pessoas devido às medidas restritivas adotadas para conter a disseminação da doença.

4.1.1 Aplicação do modelo de regressão segmentada

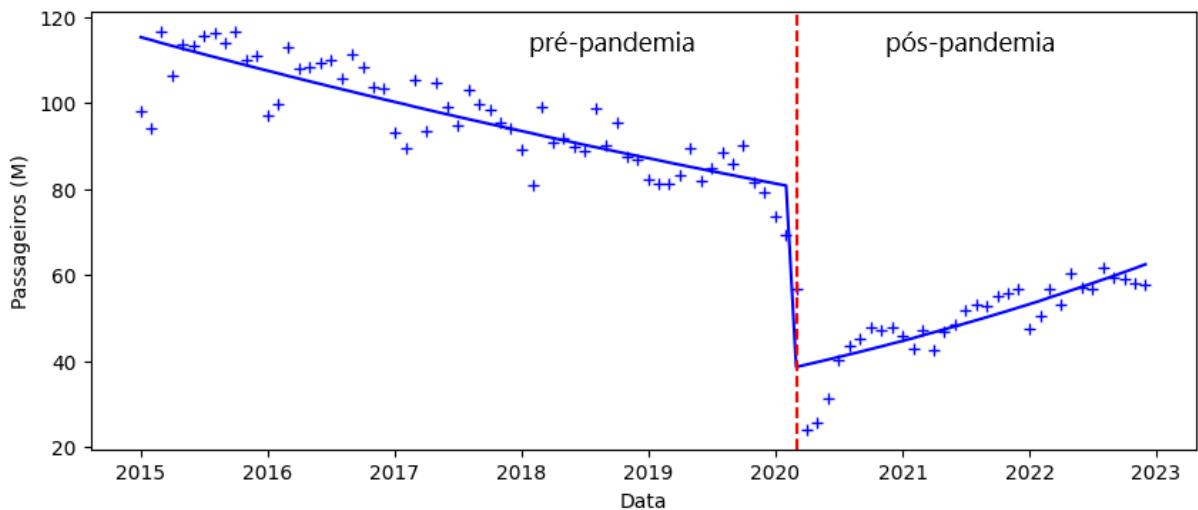
Os resultados da regressão segmentada são apresentados na Tabela 4 e todas as variáveis demonstraram serem estatisticamente significativas. O coeficiente negativo da variável “Tempo”, que representa a tendência pré-pandemia, confirma a diminuição da demanda ao longo desse período. Enquanto, durante o período pós-pandemia, houve uma mudança de inclinação na reta, representada pela variável “Tempo pós-pandemia”. Essa tendência positiva pode ser associada à flexibilização das medidas de distanciamento social e avanço do controle da doença por meio da vacinação. Além disso, o coeficiente da variável “Pandemia” confirma o efeito negativo que causou no sistema de transporte por ônibus, contribuindo para a redução na demanda. Adicionalmente, a representação gráfica do modelo é exibida na Figura 15.

Tabela 4 - Resultado dos parâmetros do modelo de regressão segmentada da série temporal do número de passageiros transportados.

Variável	Coeficiente	Erro padrão	valor-p	IC 95%
Constante	4,7529	0,025	0,000	4,704; 4,802
Tempo	-0,0058	0,001	0,000	-0,007; -0,004
Tempo pós-pandemia	0,0204	0,003	0,000	0,015; 0,026
Pandemia	-0,7538	0,059	0,000	-0,870; -0,637

Fonte: Elaboração própria.

Figura 15 - Representação do modelo de regressão segmentada da série temporal do número de passageiros transportados.



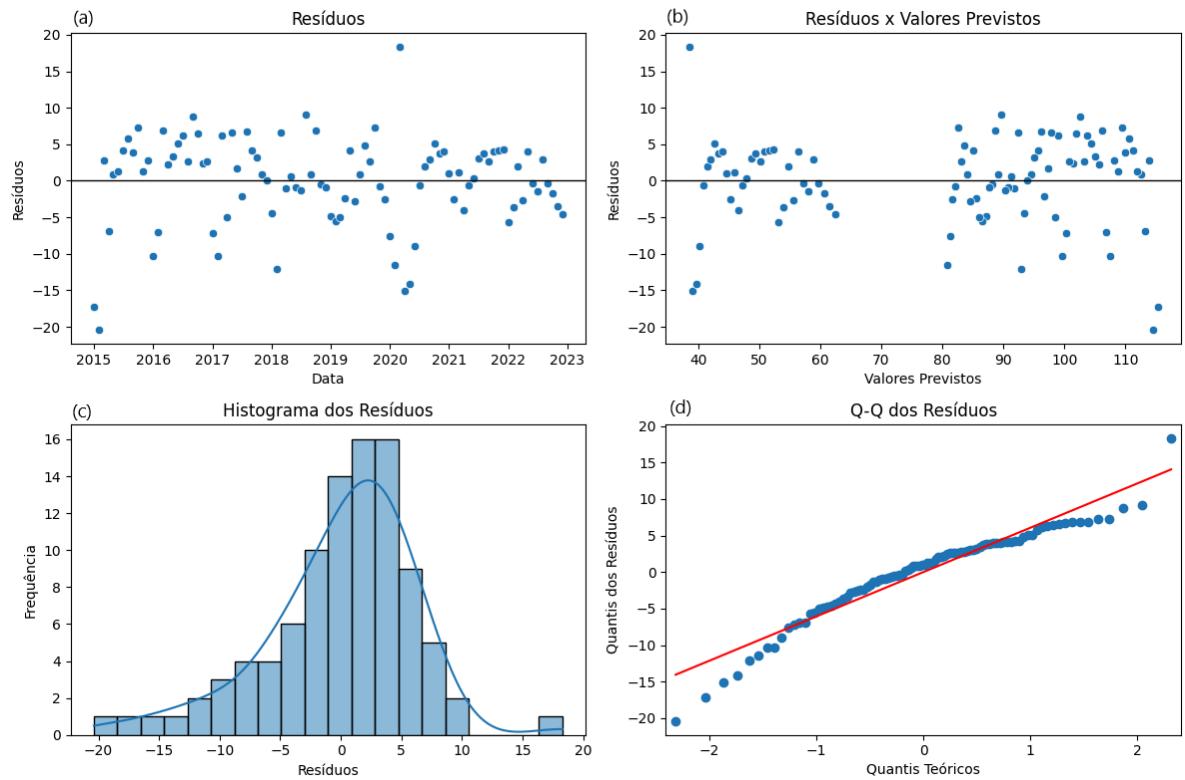
Fonte: Elaboração própria.

Visando verificar o ajuste do modelo e investigar a presença de autocorrelação entre os erros, foram calculados os valores residuais. A análise dos valores resíduos foi realizada através dos seguintes gráficos ilustrados na Figura 16: (a) resíduos ao longo do tempo, (b) resíduos versus os valores previstos, (c) histograma dos resíduos e (d) quantil-quantil dos resíduos. No gráfico dos resíduos observa-se os erros distribuídos aleatoriamente em torno de zero ao longo do tempo e o diagrama de dispersão dos resíduos versus os valores previstos não indica um padrão nos resíduos para os valores estimados pelo modelo, contudo revela um agrupamento dos resíduos para valores entre 40 e 60 e uma dispersão maior dos resíduos para os valores acima de 80. O histograma dos resíduos apresenta uma distribuição aproximadamente normal, no entanto observa-se uma frequência maior dos valores residuais positivos e no Q-Q dos resíduos nota-se que os resíduos estão concentrados próximo a reta, com isso não podemos afirmar que os resíduos possuem uma distribuição normal.

Além da análise gráfica, foi calculada a estatística DW de Durbin Watson, que auxilia na investigação de autocorrelação temporal. O valor de DW igual a 1,555 indicou que há uma autocorrelação positiva no modelo, pois de acordo com os valores críticos da estatística de Durbin Watson para nível de significância de 5%, os limites inferiores e superiores para uma amostra de 96 observações e 4 termos na regressão, são 1,6039 e 1,73256 respectivamente.

Foram calculados o coeficiente de determinação (R^2) e o coeficiente de determinação ajustado (R^2a) que indicam o quão próximo os valores previstos pelo modelo se aproximam dos valores observados. O valor do coeficiente de determinação foi de 0,9418, enquanto o coeficiente de determinação ajustado foi de 0,9392.

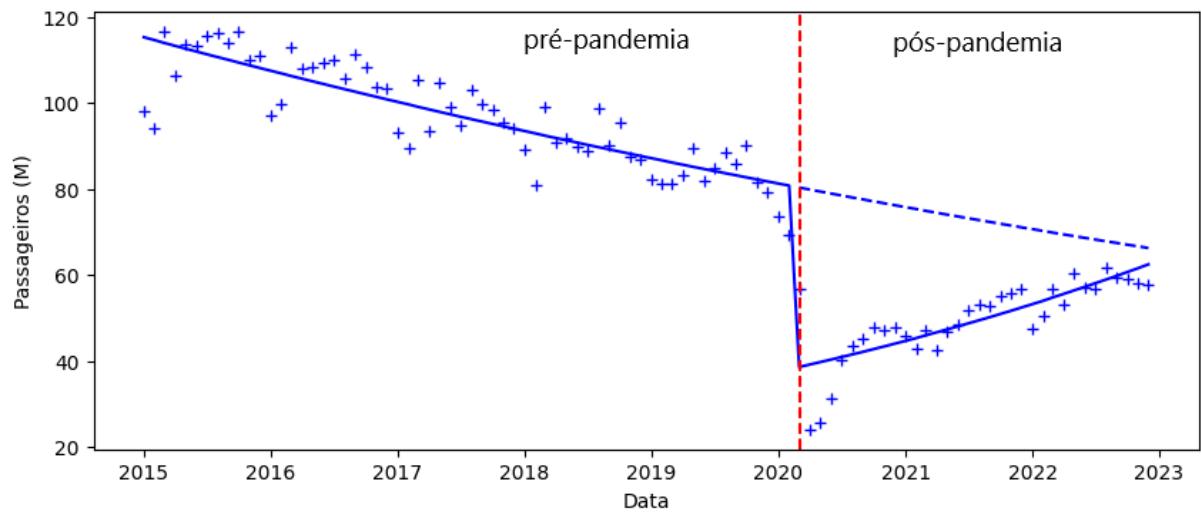
Figura 16 - Resíduos do modelo de regressão segmentada da série temporal do número de passageiros transportados.



Fonte: Elaboração própria.

Embora o modelo não atenda a todos os pressupostos de um modelo de regressão, pois os resíduos não são independentes nem normalmente distribuídos, os coeficientes de determinação indicam que o modelo apresenta um bom ajuste para representar os dados. Portanto, com o objetivo de criar uma representação visual do impacto da pandemia na demanda do transporte público, estimou-se um cenário contrafactual. Esse cenário hipotético considera como seria a tendência da demanda se a pandemia não tivesse ocorrido, mantendo a mesma tendência do período anterior à intervenção. Na Figura 17, observa-se a mudança de nível da demanda no momento do início da pandemia e a mudança da tendência ao longo dos meses.

Figura 17 - Contrafactual com base no modelo de regressão segmentada da série temporal do número de passageiros transportados.

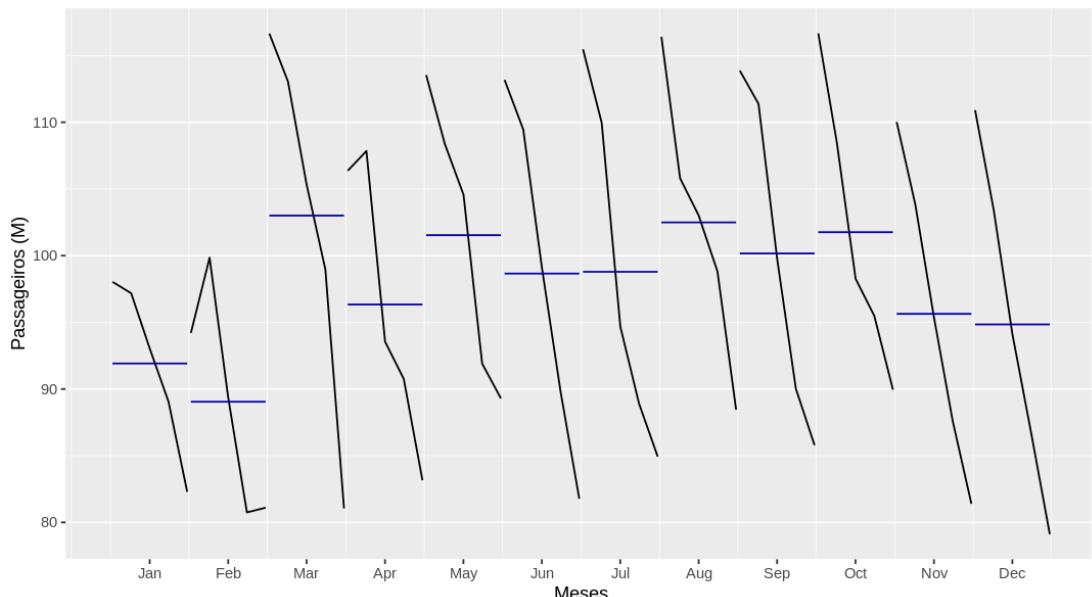


Fonte: Elaboração própria.

4.1.2 Aplicação do modelo ARIMA

Na série temporal do número de passageiros transportados na Figura 14, observa-se, no período pré-pandemia, a presença de sazonalidade na série temporal, com os meses de janeiro e fevereiro apresentando a menor demanda. Este comportamento pode estar associado ao período de férias escolares, quando há uma diminuição na movimentação de passageiros. Este comportamento sazonal fica evidente na Figura 18, na qual são apresentados os valores observados dividido por meses e um traço azul indicando os valores médios de cada mês do número de passageiros transportados do período pré-pandemia.

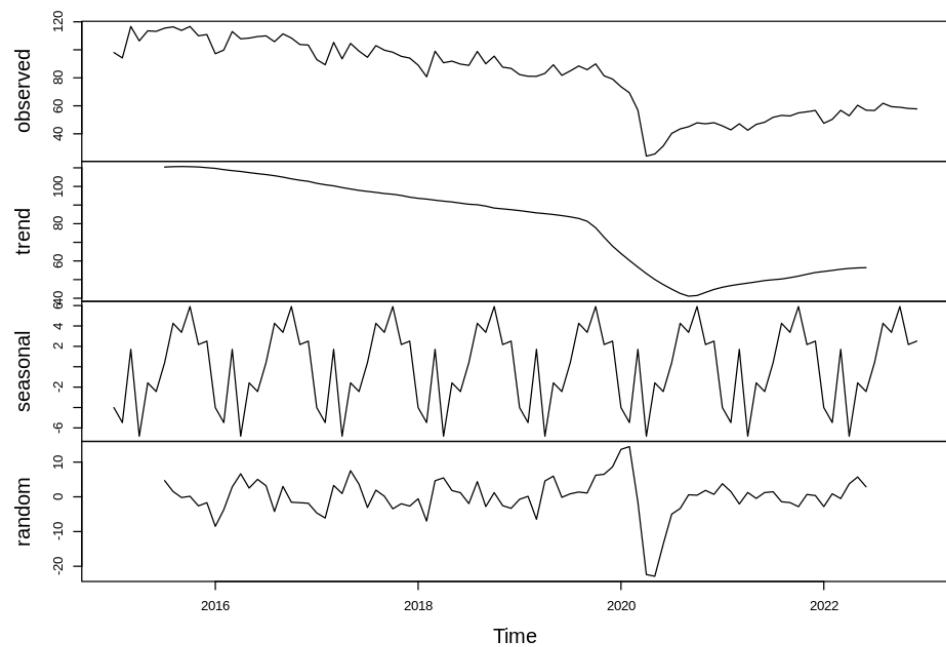
Figura 18 - Número de passageiros transportados e valor médio por mês de janeiro de 2015 a dezembro de 2019.



Fonte: Elaboração própria.

A Figura 19 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, como já mencionado.

Figura 19 - Decomposição da série temporal do número de passageiros transportados.



Fonte: Elaboração própria.

Para avaliar a estacionariedade da série, foi utilizado o teste estatístico de Dickey-Fuller Aumentado. Os resultados do teste, apresentados na Tabela 5, indicam que a série, sem aplicar nenhuma diferenciação, não é estacionária, conforme evidenciado pelo valor-p superior ao nível de significância de 5%.

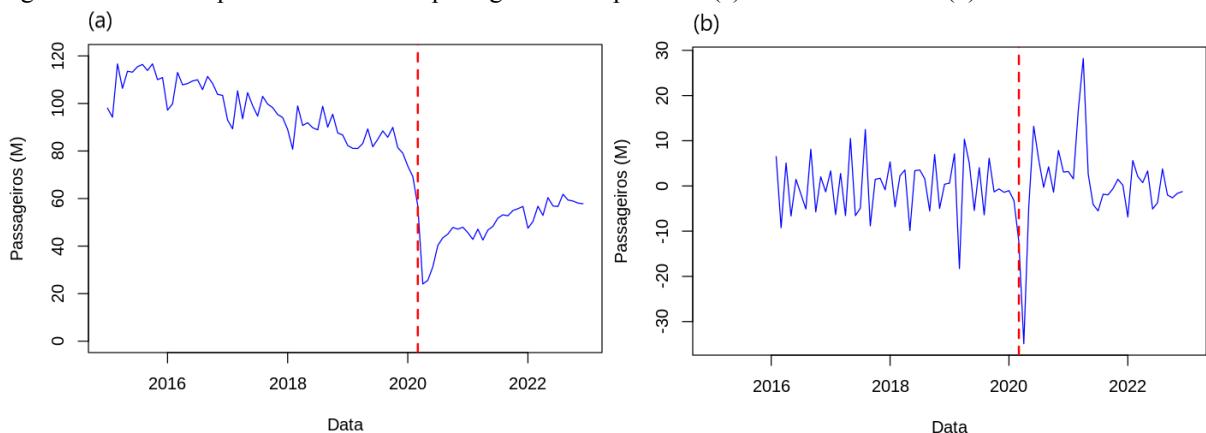
Tabela 5 - Teste de Dickey-Fuller Aumentado da série temporal do número de passageiros transportados.

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

Fonte: Elaboração própria.

Examinando o comportamento da série é visível a tendência decrescente antes da pandemia e a sazonalidade como pode ser visto na Figura 20(a) da série sem nenhuma diferenciação. Sendo assim, a diferenciação foi aplicada à série para torná-la estacionária. Foi necessário realizar duas diferenciações para obter a estacionariedade da série, sendo a segunda uma diferenciação 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 5. A série após essas diferenciações terem sido aplicadas foi representada na Figura 20(b).

Figura 20: Série temporal do número de passageiros transportados (a) não estacionária e (b) estacionária.



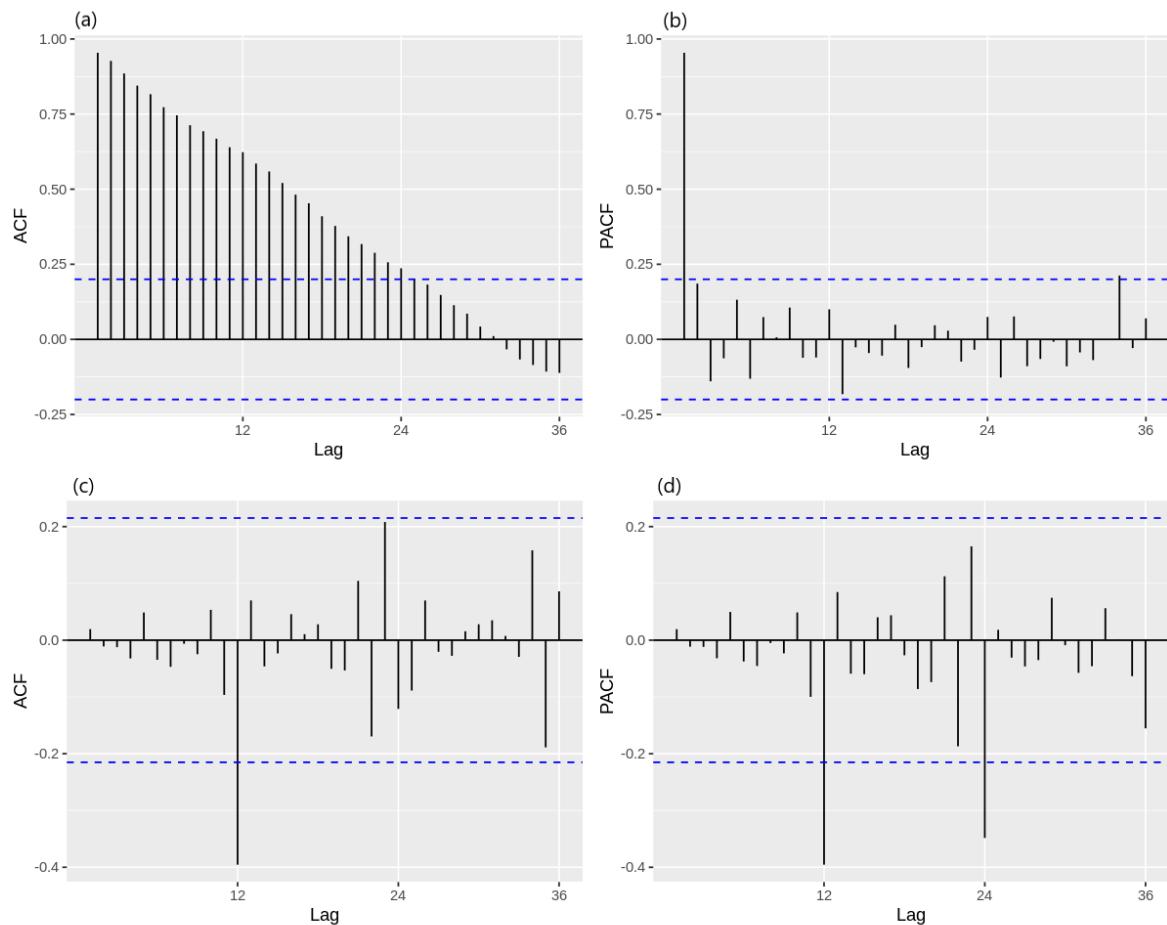
Fonte: Elaboração própria.

Os gráficos da função de autocorrelação (ACF) e da função de autocorrelação parcial (PACF) estão representados na Figura 21. Nesses gráficos, as barras que ultrapassam a linha tracejada para cima ou para baixo indicam autocorrelação estatisticamente significativa (SCHAFFER *et al.*, 2021). Como o esperado, os gráficos na Figura 21(a) e (b), mostram valores positivos que diminuem lentamente devido à tendência da série, além de valores

maiores em alguns lags devido a sazonalidade. Ao analisar a Figura 21(c) e (d), observa-se que a maior parte da autocorrelação da série foi removida com as diferenciações.

Com base nesses resultados, definiu-se a ordem d e D igual a 1. No modelo SARIMA, o parâmetro "d" representa o número de diferenciações necessárias para tornar a série temporal estacionária, enquanto o parâmetro "D" representa o número de diferenciações sazonais necessárias.

Figura 21 - Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da série temporal do número de passageiros transportados (a) e (b) não estacionária e (c) e (d) estacionária.



Fonte: Elaboração própria.

Utilizando a função `auto.arima` com a inclusão das variáveis exógenas “nível” e “rampa” e limitando os valores máximos de diferenciação sazonal e não sazonal a 1, o algoritmo identificou o modelo SARIMA(0,1,1)(2,0,0)₁₂ como o mais adequado. Resumidamente, esse modelo consiste em uma parte diferenciada de ordem 1, um termo de média móvel de ordem 1 e um componente sazonal com uma ordem de autocorrelação de 2. Os resultados do modelo estão dispostos na Tabela 6, na qual são fornecidos os coeficientes, erros padrão, valores-p e intervalos de confiança (IC) para cada parâmetro estimado. Todos os

parâmetros estimados são considerados significativos, visto que apresentam valor-p inferior a 0,05. Os critérios de informação do modelo selecionado apresentaram valores de 599,94 para o AIC e 615,29 para o BIC.

Tabela 6 - Resultado dos parâmetros do modelo SARIMA(0,1,1)(2,0,0)12 da série temporal do número de passageiros transportados.

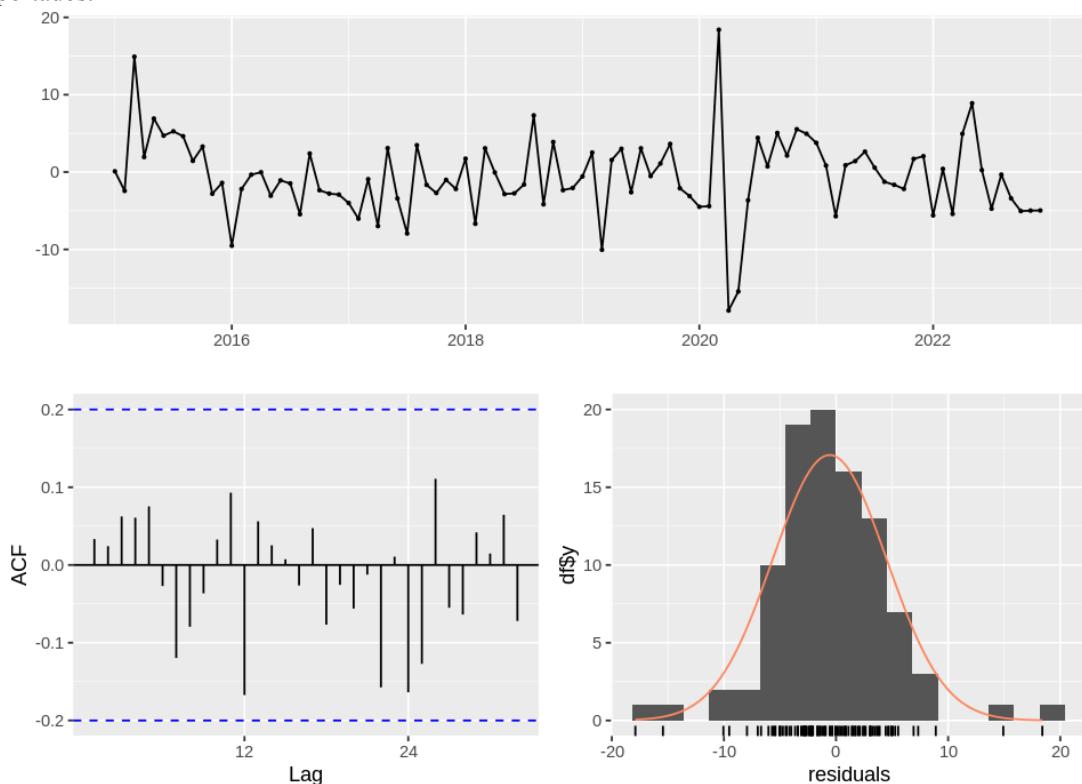
Parâmetro	Coeficiente	Erro padrão	valor-p	IC 95%
MA	-0,7490	0,089	0,0000	-0,92; -0,57
SAR1	0,3419	0,0937	0,0003	0,16; 0,52
SAR2	0,3541	0,0982	0,0003	0,16; 0,55
Nível	-41,6334	3,3483	0,0000	-48,20; -35,07
Rampa	1,0787	0,3383	0,0014	0,42; 1,74

Fonte: Elaboração própria.

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 22. A análise dos resíduos evidencia a adequação do modelo SARIMA(0,1,1)(2,0,0)12 para representar a série temporal do número de passageiros transportados. No primeiro gráfico, que exibe os resíduos em ordem temporal, é observado que os resíduos estão distribuídos aleatoriamente em torno de zero, indicando que são independentes entre si. Além disso, a análise do gráfico da função de autocorrelação (ACF) revela que os resíduos se mantêm dentro dos limites esperados, não apresentando correlação significativa. Por fim, no gráfico inferior direito, é possível visualizar que os resíduos seguem uma distribuição aproximadamente normal.

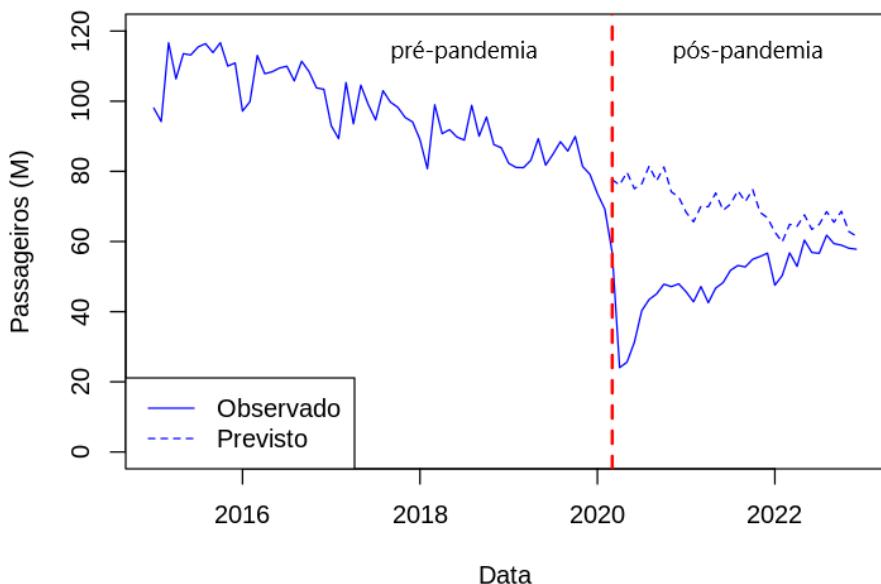
Figura 22 - Resíduos do modelo SARIMA(0,1,1)(2,0,0)12 da série temporal do número de passageiros transportados.



Fonte: Elaboração própria.

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, foi previsto o número de passageiros transportados considerando um cenário hipotético no qual a pandemia não tivesse ocorrido, chamado de cenário contrafactual. Os valores previstos, juntamente com os valores observados, são apresentados na Figura 23. Observa-se uma mudança de nível da série, indicando uma redução estimada de 20,8 milhões passageiros no mês de março de 2020.

Figura 23 - Valores observados e valores previstos na ausência da pandemia com base no modelo SARIMA(0,1,1)(2,0,0)12 da série temporal do número de passageiros transportados.



Fonte: Elaboração própria.

Foi calculada a diferença entre os valores observados e previstos no período pós-pandemia, assim como a variação percentual entre esses valores, conforme apresentados no Apêndice A. Os meses que apresentaram as maiores diferenças absolutas e variações percentuais foram maio e abril de 2020, com uma diferença de -54,1 e -52,1 milhões de passageiros respectivamente. Por outro lado, o mês de dezembro de 2022 registrou a menor diferença e variação percentual entre os valores previstos e os observados, com uma diferença de -3,8 milhões de passageiros e uma variação percentual de -6,1%. Isso 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. Essa 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 de 29,47% no volume de passageiros, totalizando aproximadamente 704 milhões de usuários. Essa redução da demanda, somada às quedas registradas nos anos anteriores, levanta preocupações sobre a 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, no mês de 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, no qual ficou acordada a manutenção do valor da tarifa de ônibus vigente na

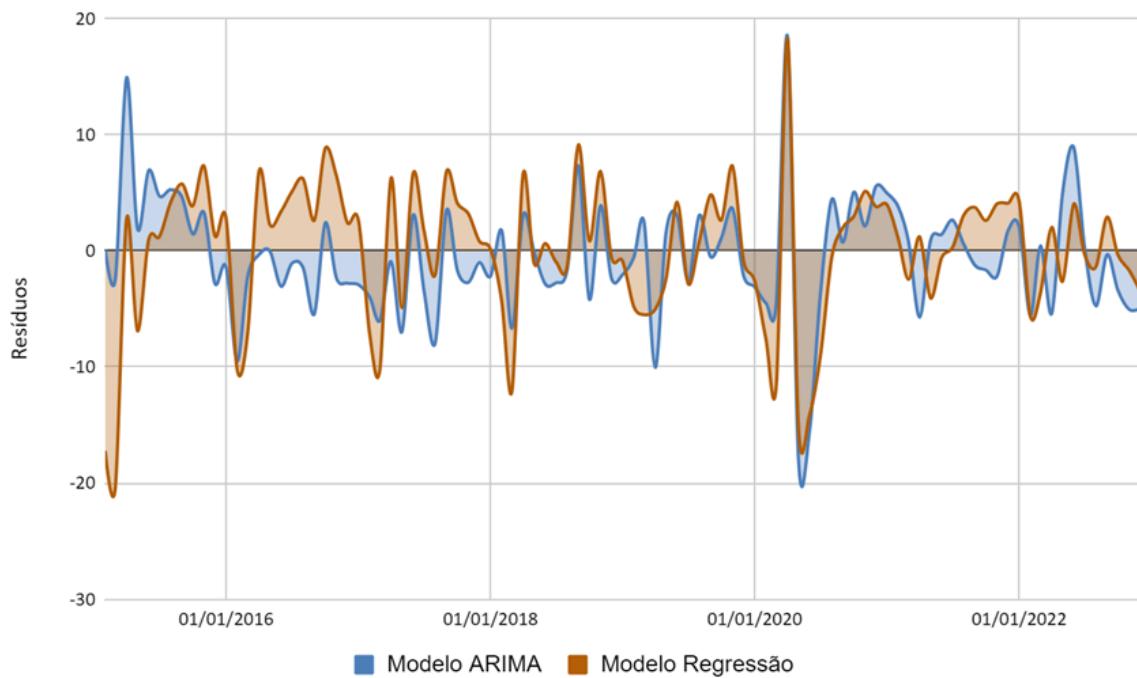
época, mediante o pagamento de subsídio às empresas de ônibus (SMTR, 2023b). O acordo entrou em vigor a partir de junho de 2022. Durante o período de junho a dezembro de 2022, foram alocados recursos no valor total de R\$232.860.345 como subsídios às empresas (SMTR, 2023c).

4.1.3 Comparação entre os modelos

A análise do impacto da pandemia no número de passageiros transportados no transporte público por ônibus foi conduzida por meio da aplicação do modelo de regressão segmentada e do modelo ARIMA. Com a finalidade de avaliar o ajuste desses modelos, foi observado o comportamento residual dos modelos. Verificou-se que os resíduos do modelo de regressão segmentada apresentou uma distribuição aproximadamente normal, contudo a aplicação do teste de Durbin-Watson indicou a presença de autocorrelação positiva nos resíduos. Por outro lado, os resíduos do modelo ARIMA apresentaram uma distribuição normal e o teste de Ljung-Box empregado para avaliar a autocorrelação nos resíduos, indicou que os resíduos não estavam correlacionados.

A Figura 24 apresenta os resíduos de ambos os modelos. Considerando o período anterior à pandemia, é possível perceber que os resíduos do modelo de regressão segmentada apresentam os maiores erros nos meses de janeiro e fevereiro dos anos de 2015 a 2018, com estimativas abaixo dos valores observados. Isso ocorre porque não foi incorporado ao modelo de regressão uma variável sazonal que pudesse ajustar essa característica da série. Enquanto os resíduos do modelo ARIMA não demonstram o mesmo padrão, uma vez que utilizamos o modelo SARIMA.

Figura 24 - Resíduos do modelo de regressão segmentada e ARIMA da série temporal do número de passageiros transportados.



Fonte: Elaboração própria.

As métricas de avaliação do modelo de regressão segmentada e do modelo SARIMA foram calculadas e estão resumidas na Tabela 7. Observa-se que o modelo ARIMA apresentou o melhor ajuste, ou seja, os menores erros de previsão, conforme pode ser visto por meio das medidas de acurácia erro quadrático médio (MSE), a raiz do erro quadrático médio (RMSE) e o erro percentual absoluto médio (MAPE).

Tabela 7 - Métricas de avaliação do modelo de regressão segmentada e do modelo ARIMA da série temporal do número de passageiros transportados.

Modelo	MAE	RMSE	MAPE
Regressão segmentada	4,5845	6,0730	6,8403
ARIMA	3,7503	5,0954	6,0813

Fonte: Elaboração própria.

Apesar do modelo de regressão segmentada não ter apresentado o melhor ajuste dos dados, isso não inutiliza a modelagem desenvolvida, pois o modelo fornece uma estimativa da relação entre a pandemia e o número de passageiros transportados. Assim como, sua representação gráfica oferece uma visão intuitiva da tendência do período pré-pandemia e

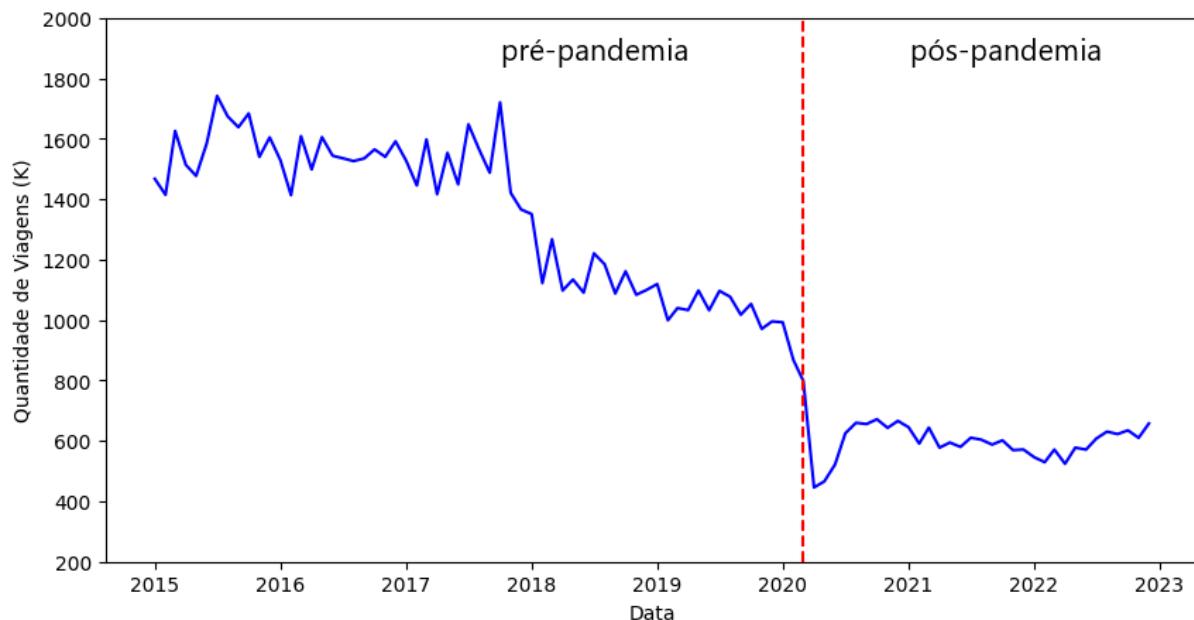
pós-pandemia, assim como a mudança de nível que ocorreu imediatamente no início do período pandêmico.

Adicionalmente, Bernal *et al.* (2017) elucidam que características da série temporal, como superdispersão e sazonalidade, requerem uma aprimoração do modelo. Afirram que para lidar com a superdispersão, pode ser considerada a utilização do modelo de quasi-poisson, enquanto a sazonalidade dos dados pode ser abordada por meio da incorporação de uma variável sazonal no modelo, como termos de Fourier.

4.2 QUANTIDADE DE VIAGENS REALIZADAS

A série temporal da quantidade de viagens realizadas mensalmente no período de janeiro de 2015 a dezembro de 2022 é ilustrada na Figura 25. Ao analisar a série, é perceptível o comportamento decrescente da oferta de transporte público por ônibus ao longo dos últimos anos. Entre os anos de 2015 a 2019, houve uma redução de aproximadamente 34% da oferta. Enquanto, entre os anos de 2020 a 2022, com o início da crise sanitária, a redução da oferta chegou a 43,3% quando comparado ao ano de 2019.

Figura 25 - Série temporal da quantidade de viagens realizadas.



Fonte: Elaboração própria a partir de dados da SMTR.

A quantidade de viagens realizadas em cada ano e a variação percentual em relação ao ano anterior são apresentadas na Tabela 8. Observa-se uma tendência de diminuição consecutiva da quantidade de viagens entre os anos de 2015 a 2019, sendo a redução mais expressiva no ano de 2018, com uma diminuição de 23,61% da oferta. Com o advento da

pandemia em 2020 e consequentemente o fechamento de comércios, serviços, indústrias, escolas e outros polos geradores de viagens, houve uma redução ainda mais significativa do nível de oferta de transporte público por ônibus. Isso resultou em uma diminuição de 36,05% no primeiro ano de pandemia, refletindo o efeito das medidas de enfrentamento da pandemia na mobilidade urbana.

Tabela 8 - Quantidade de viagens realizadas e variação percentual.

Ano	Quantidade de viagens (K)	Variação percentual (%)
2015	18962,77	
2016	18488,50	-2,50
2017	18193,25	-1,60
2018	13897,66	-23,61
2019	12529,39	-9,85
2020	8011,94	-36,05
2021	7175,62	-10,44
2022	7082,32	-1,30

Fonte: Elaboração própria a partir de dados da SMTR.

As medidas descritivas da série no período pré-pandemia e pós-pandemia estão resumidas na Tabela 9. Verifica-se uma redução de aproximadamente 55,7% na média mensal de viagens no período pós-pandemia. O desvio padrão também diminuiu, indicando uma variação menor no número de viagens realizadas após a pandemia. A assimetria mudou de uma leve inclinação para a esquerda para uma leve inclinação para a direita no pós-pandemia, indicando que as quantidades de viagens realizadas nesse período estão concentradas abaixo da média. A curtose aumentou no período pós-pandemia, sugerindo uma concentração maior de dados em torno da média e a presença de extremos mais evidentes.

Tabela 9 - Estatísticas descritivas da quantidade de viagens realizadas.

Estatísticas	Pré-pandemia	Pós-pandemia
Média	1353,74	600,29
Desvio padrão	243,92	62,95
Mínimo	867,77	445,78
1º Quartil	1097,55	571,31
Mediana	1432,87	602,71
3º Quartil	1550,75	640,98
Máximo	1741,58	798,00
Assimetria	-0,28	0,20
Curtose	-1,43	2,43

Fonte: Elaboração própria a partir de dados da SMTR.

Antes da pandemia, o mês com o maior número de viagens realizadas foi julho de 2015 e o mês com o menor número foi em fevereiro de 2020. Já após a pandemia, o maior e o menor número de viagens realizadas foram registrados em março de 2020 e em abril de 2020, respectivamente. Analisando as estatísticas descritivas das quantidades de viagens realizadas antes e depois do início da pandemia, observou-se uma diminuição considerável em todos os aspectos.

4.2.1 Aplicação do modelo de regressão segmentada

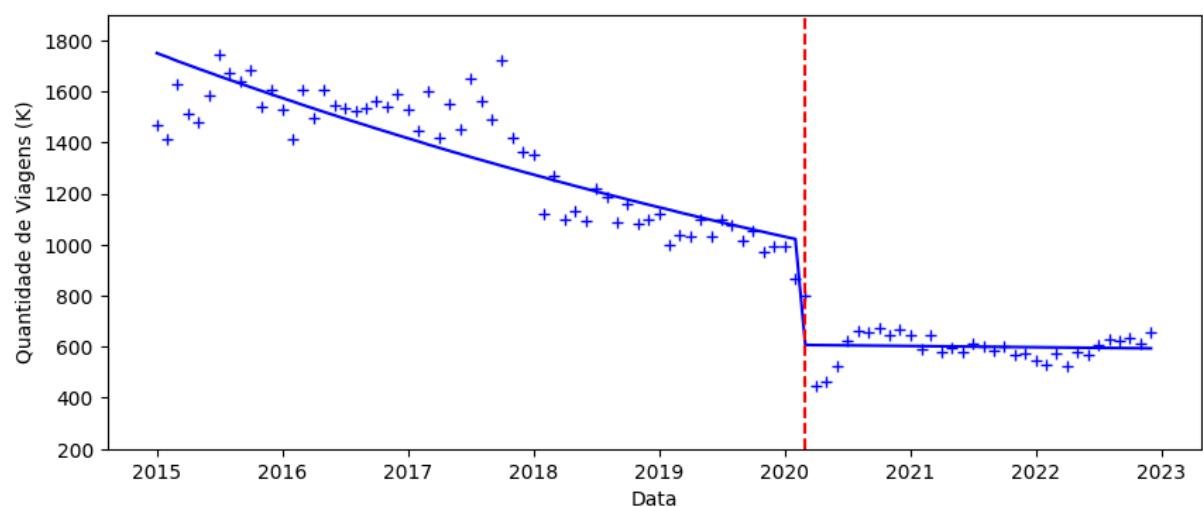
No ajuste do modelo de regressão segmentada, foram utilizadas três variáveis independentes. A variável “Tempo” representando o tempo decorrido desde o início da série, a variável “Tempo pós-pandemia” representando o tempo decorrido desde o início da pandemia e a variável “Pandemia” representando o período antes da pandemia e depois da pandemia. Os resultados do modelo estão resumidos na Tabela 10, enquanto a representação gráfica está disponível na Figura 26. Ao observar os valores-p, conclui-se que todas as variáveis são estatisticamente significativas.

Tabela 10 - Resultado dos parâmetros do modelo de regressão segmentada da série temporal da quantidade de viagens realizadas.

Variável	Coeficiente	Erro padrão	valor-p	IC 95%
Constante	7,4759	0,007	0,000	7,463; 7,489
Tempo	-0,0088	0,000	0,000	-0,009; -0,008
Tempo pós-pandemia	0,0081	0,001	0,000	-0,007; 0,010
Pandemia	-0,5202	0,016	0,000	-0,552; 0,489

Fonte: Elaboração própria.

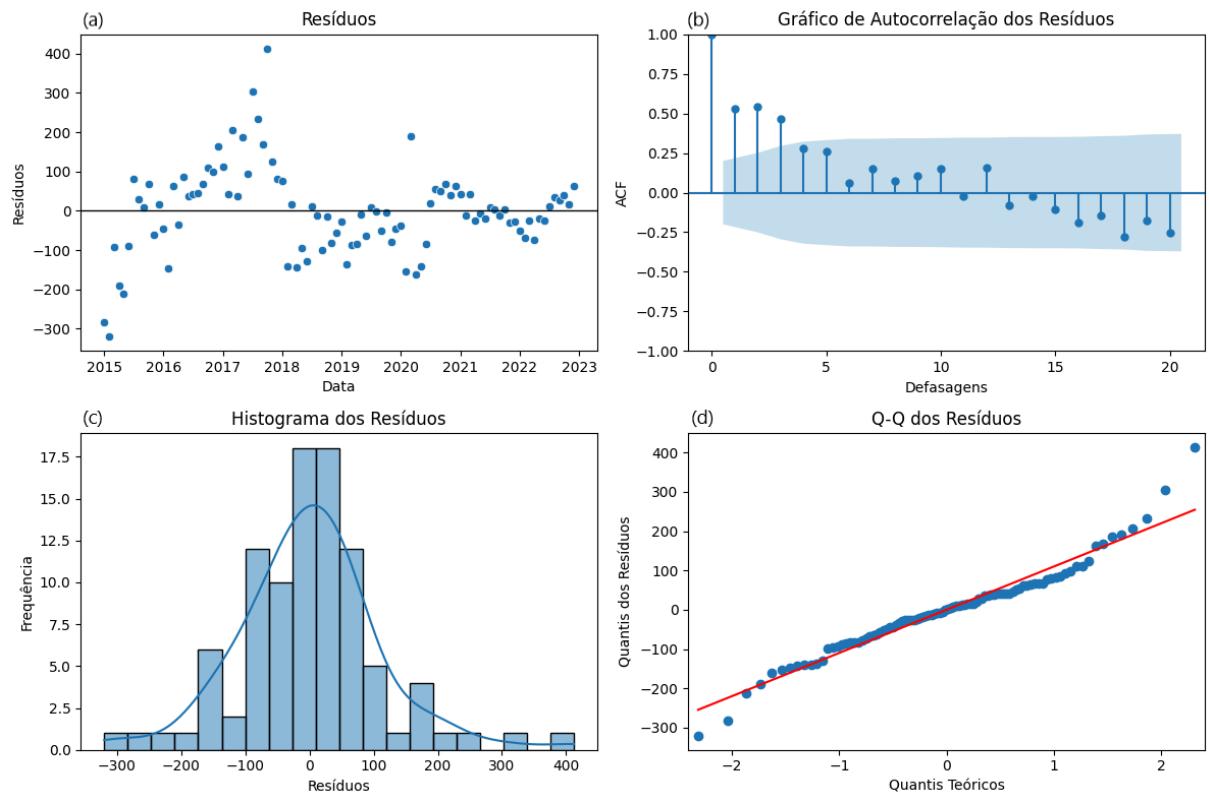
Figura 26 - Representação do modelo de regressão segmentada da série temporal da quantidade de viagens realizadas.



Fonte: Elaboração própria.

A análise dos resíduos na Figura 27(a) indica que eles não estão distribuídos aleatoriamente em torno de zero, com uma maior dispersão nos primeiros anos e uma menor dispersão nos anos finais. Isso sugere a presença de autocorrelação, o que é confirmado pelo gráfico ACF na Figura 27(b). Além disso, em relação ao pressuposto da normalidade dos resíduos, tanto o histograma na Figura 27(c) quanto o Q-Q plot dos resíduos na Figura 27(d) não sugerem uma distribuição normal para os resíduos.

Figura 27 - Resíduos do modelo de regressão segmentada da série temporal da quantidade de viagens realizadas.



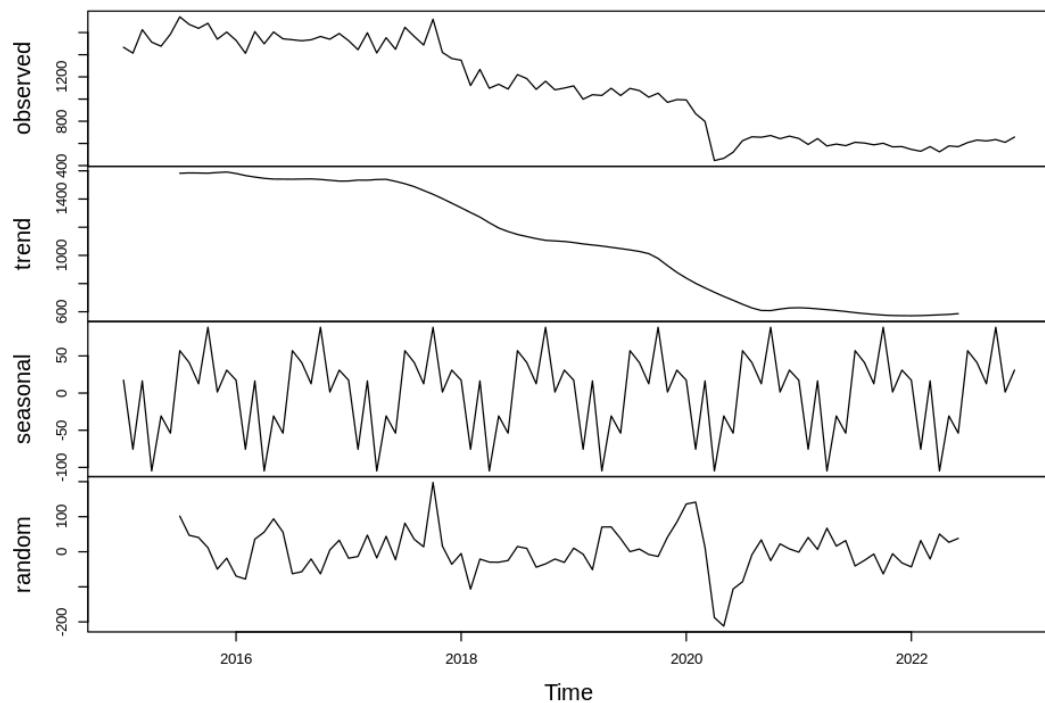
Fonte: Elaboração própria.

Além disso, foi aplicado o teste de Durbin-Watson para avaliar a presença de autocorrelação nos resíduos. O resultado do teste indicou a presença de autocorrelação positiva, com o valor de DW igual a 0,7885. O limite inferior para a estatística DW, considerando uma amostra de 96 observações e 4 termos na regressão, é de 1,6039. Portanto, um valor abaixo desse limite sugere que os resíduos possuem autocorrelação positiva.

4.2.2 Aplicação do modelo ARIMA

A Figura 28 evidencia os componentes de tendência, sazonalidade e variações irregulares da série mensal da quantidade de viagens realizadas. Percebe-se que a tendência decrescente da série se acentua ao decorrer dos anos, como evidenciado pelas variações negativas entre os anos mencionadas anteriormente. A manifestação dos padrões sazonais fica mais evidente na Figura 29, que ilustra as observações separadas por mês, com as médias de cada mês indicadas por linhas horizontais em azul.

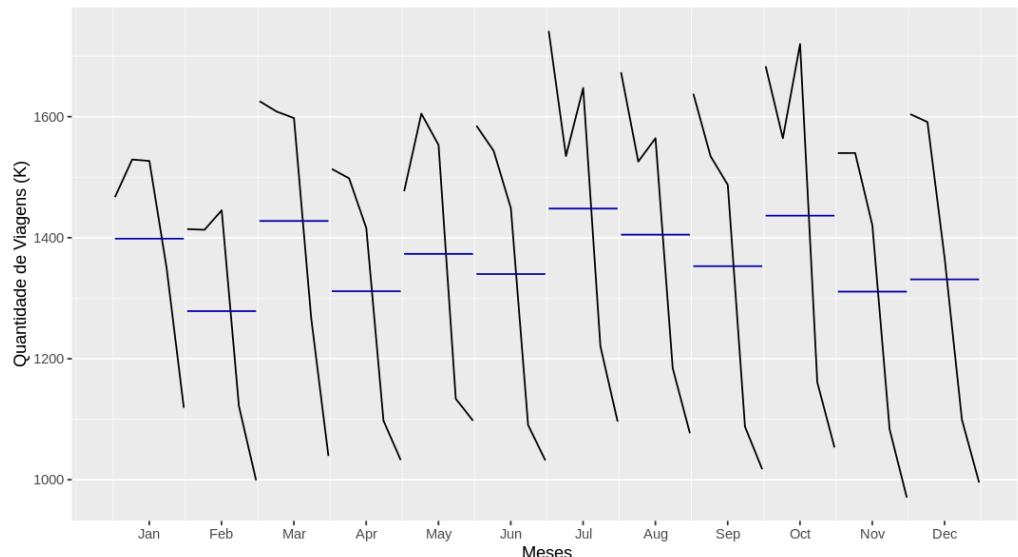
Figura 28 - Decomposição da série temporal da quantidade de viagens realizadas.



Fonte: Elaboração própria.

Na Figura 29, verifica-se que nos meses de fevereiro, abril e novembro, a oferta do serviço é significativamente menor, o que pode ser atribuído a fatores como férias escolares ou feriados. Por outro lado, nos meses de março, julho e outubro, a oferta do serviço aumenta, possivelmente associado ao retorno das atividades após as férias ou outros fatores sazonais.

Figura 29 - Quantidade de viagens realizadas e valor médio por mês de janeiro de 2015 a dezembro de 2019.

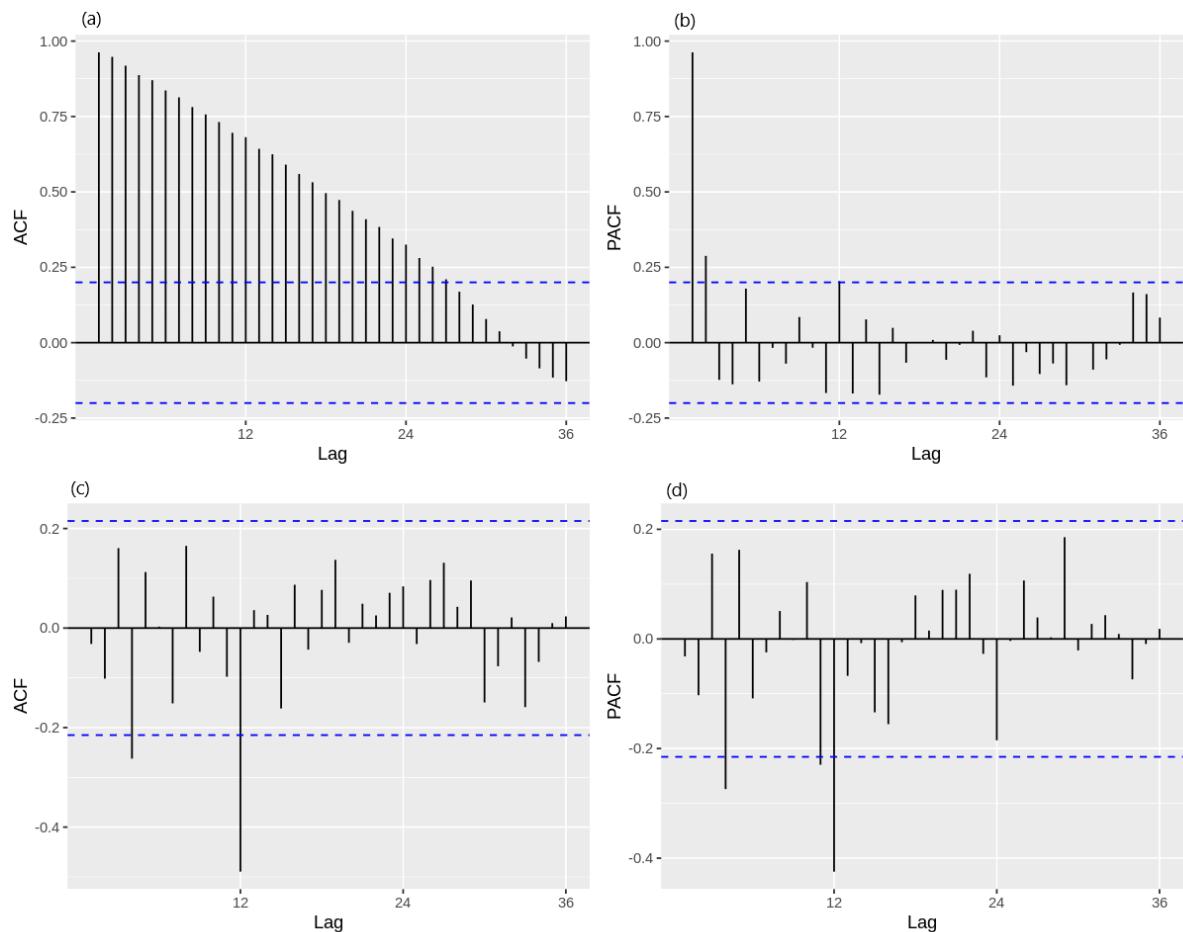


Fonte: Elaboração própria.

A presença desses componentes torna a série não estacionária. Essa característica é confirmada pela análise dos gráficos de ACF e PACF na Figura 30 (a) e (b), que indicam a presença de autocorrelação na série. Assim como, o teste estatístico de Dickey-Fuller Aumentado apresentou um p-valor igual a 0,2635, indicando a não estacionariedade da série. No entanto, após a aplicação da diferenciação na série e a realização do teste de Dickey-Fuller Aumentado novamente, o p-valor foi igual a 0,01, confirmando a estacionariedade da série.

Com o objetivo de confirmar a presença de sazonalidade na série, foram gerados os gráficos de ACF e PACF com diferenciação de primeira ordem e sazonal, como apresentados na Figura 30 (c) e (d). Esses gráficos revelam que a autocorrelação na série atinge seu valor mais alto no lag 12, sugerindo a influência da sazonalidade a cada intervalo de 12 meses. Isso reforça a presença de sazonalidade na série da quantidade de viagens realizadas.

Figura 30 - Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da série temporal da quantidade de viagens realizadas (a) e (b) antes da diferenciação e (c) e (d) depois da diferenciação de primeira ordem e sazonal.



Fonte: Elaboração própria.

Após tornar a série estacionária, a próxima etapa é a seleção do modelo. Essa seleção foi realizada através da função *auto.arima*. As medidas restritivas decretadas pelo governo municipal tiveram um efeito imediato na quantidade de viagens realizadas, provocando uma mudança no nível da série. Para incorporar esse efeito, foi adicionada a variável exógena "nível" ao modelo. A análise da série sugere que a tendência negativa não foi alterada após a pandemia, contudo para avaliar se houve uma mudança significativa na tendência da série, introduziu-se a variável exógena "rampa".

O modelo selecionado com as duas variáveis incorporadas mostraram que a variável "nível" é estatisticamente significativa, enquanto a variável "rampa" não apresentou significância estatística. Portanto, diante da falta de evidências estatísticas de uma mudança significativa na tendência durante o período pós-pandemia, a variável "rampa" foi retirada do modelo. A seleção automática indicou o modelo SARIMA(2,1,1)(2,0,0)12 como o mais adequado com base nos critérios de informação, apresentando um AIC de 1090,70 e um BIC de 1108,58. Os resultados do modelo são apresentados na Tabela 11, na qual estão os coeficientes, erros padrão, valores-p e intervalos de confiança (IC) para cada parâmetro estimado. Todos os parâmetros estimados são considerados estatisticamente significativos, uma vez que possuem valores-p menores que 0,05.

Tabela 11 - Resultado dos parâmetros do modelo SARIMA(2,1,1)(2,0,0)12 da série temporal da quantidade de viagens realizadas.

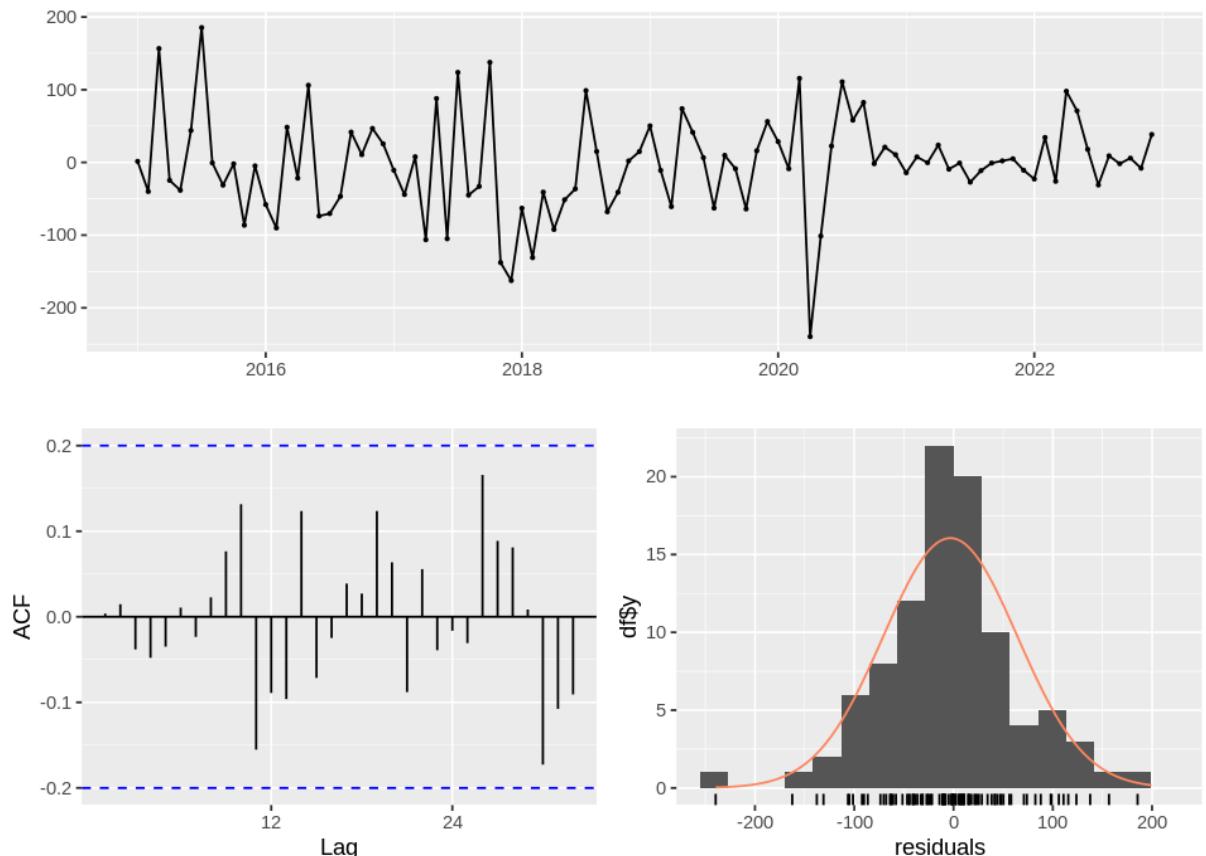
Parâmetro	Coeficiente	Erro padrão	valor-p	IC 95%
AR1	-1,0478	0,1788	0,000	-1,40; -0,70
AR2	-0,4279	0,0974	0,000	-0,62; -0,24
MA	0,6524	0,1803	0,000	0,30; 1,00
SAR1	0,2419	0,0942	0,010	0,06; 0,43
SAR2	0,3902	0,0930	0,000	0,21; 0,57
Nível	-253,5559	61,7192	0,000	-374,52; -132,59

Fonte:Elaboração própria.

Na última etapa de verificação do modelo, a análise dos resíduos foi realizada com base nos gráficos apresentados na Figura 31. No primeiro gráfico, que exibe os resíduos ao longo do tempo, observa-se que os erros estão distribuídos de maneira aleatória em torno de zero, sugerindo independência entre eles. Ao analisar o gráfico da função de autocorrelação (ACF), verifica-se que os resíduos não ultrapassam os limites dos intervalos de confiança, indicando a ausência de correlações estatisticamente significativas. No último gráfico, o

histograma dos resíduos, infere-se que os resíduos seguem uma distribuição aproximadamente normal.

Figura 31 - Resíduos do modelo SARIMA(0,1,1)(2,0,0)12 da série temporal da quantidade de viagens realizadas.



Fonte: Elaboração própria.

O teste de Ljung-Box foi aplicado com 24 defasagens, resultando em um valor-p de 0,9365. A hipótese nula foi aceita com base nesse resultado, indicando que os resíduos não apresentam correlação significativa entre si. Portanto, os resíduos são considerados independentes e não autocorrelacionados.

Adicionalmente, as métricas de acurácia erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE) e erro percentual absoluto médio (MAPE), apontaram para um melhor ajuste dos dados pelo modelo ARIMA. As medidas de avaliação referentes tanto ao modelo de regressão segmentada quanto ao modelo ARIMA são apresentadas na Tabela 12. Uma análise dos resultados revela que os erros associados ao modelo ARIMA são inferiores, indicando um desempenho superior em relação à modelagem de regressão segmentada.

Tabela 12 - Métricas de avaliação do modelo de regressão segmentada e do modelo ARIMA da série temporal da quantidade de viagens realizadas.

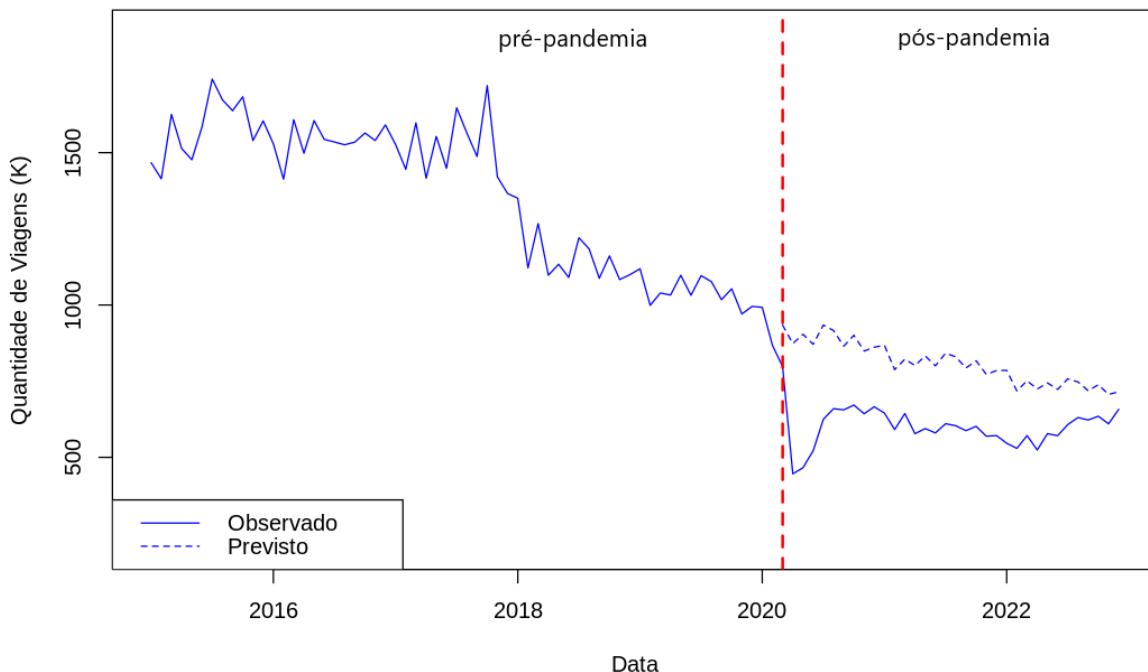
Modelo	MAE	RMSE	MAPE
Regressão segmentada	79,37	109,93	7,41
ARIMA	48,44	67,31	4,92

Fonte: Elaboração própria.

Diante dessa melhor performance do modelo ARIMA, ele foi utilizado para estimar o cenário contrafactual da quantidade de viagens realizadas. Os valores observados e previstos, juntamente com a diferença e a variação percentual entre eles, estão detalhados no Apêndice B. Os valores previstos do cenário contrafactual indicam uma redução estimada de 7.078.182 viagens, o que corresponde a uma contração de 25,75% no nível de oferta do serviço de transporte público por ônibus no período entre março de 2020 a dezembro de 2022. O mês com a maior redução da oferta de viagens foi o mês de abril de 2020 com uma redução de 48,97%. Enquanto o mês com a menor variação percentual foi dezembro de 2022 com uma redução de 8,01%.

A Figura 32 apresenta a representação gráfica do cenário contrafactual, exibindo tanto os valores observados como os valores previstos para esse cenário hipotético. A mudança de nível da série é estimada com uma redução de 135.770 viagens em março de 2020. Apesar da expressiva redução da oferta do serviço no período anterior à pandemia, o cenário contrafactual evidencia uma redução ainda mais acentuada durante a pandemia. Nesse contexto, a diminuição da quantidade de viagens realizadas pode ter afetado diversos aspectos, como a qualidade das viagens, o tempo de espera, a duração das viagens e a lotação dos veículos, influenciado diretamente nas escolhas de transporte da população. Além disso, a redução da oferta do serviço provavelmente teve impactos significativos no cumprimento das medidas de distanciamento social necessárias durante a crise sanitária. A superlotação e a proximidade entre os passageiros nos veículos podem ter representado um desafio adicional na prevenção da propagação da doença.

Figura 32 - Valores observados e valores previstos na ausência da pandemia com base no modelo SARIMA(2,1,1)(2,0,0)12 da série temporal da quantidade de viagens realizadas.

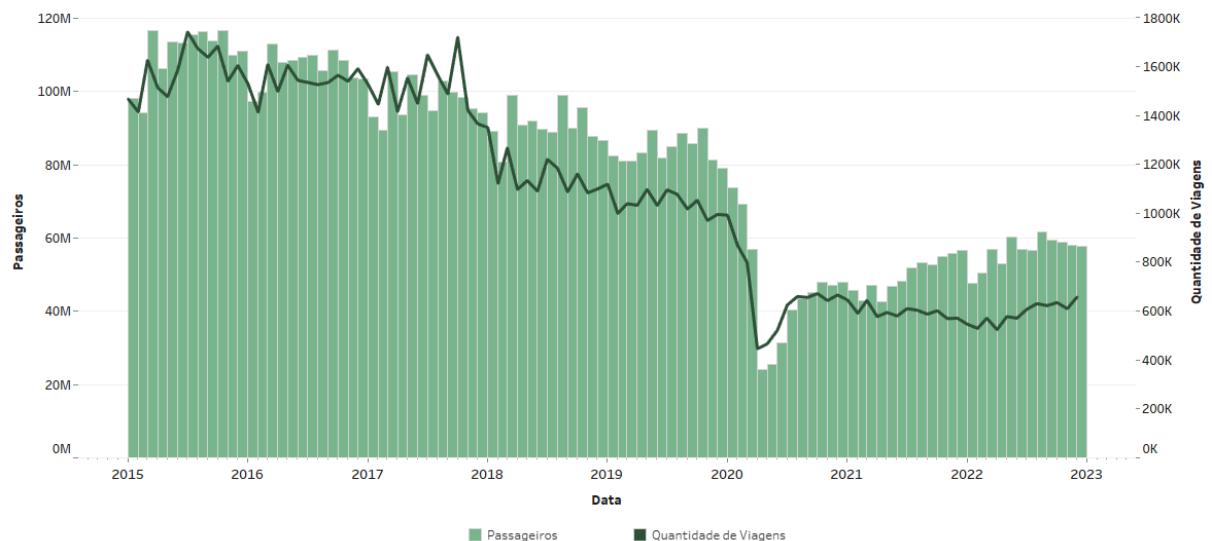


Fonte: Elaboração própria.

4.3 QUANTIDADE DE PASSAGEIROS TRANSPORTADOS VERSUS QUANTIDADE DE VIAGENS REALIZADAS

No período de 2015 a 2019, a demanda do transporte público por ônibus diminuiu em 23,9%, enquanto a oferta do serviço reduziu em 34%. A Figura 33, que exibe o número de passageiros transportados e a quantidade de viagens realizadas entre 2015 e 2022, demonstra que nos anos de 2018 e 2019, houve uma maior redução da oferta em comparação à redução da demanda. Em 2018, a quantidade de viagens realizadas reduziu 23,61%, no entanto o número de passageiros transportados diminuiu 6,94%. Segundo Bazani (2018a), entre 2015 a 2018, 10 empresas operadoras do transporte público por ônibus no município deixaram de operar devido à falta de reajuste da tarifa, a atuação de transportes irregulares e a recessão econômica desde 2014.

Figura 33 - Evolução do número de passageiros transportados e quantidade de viagens realizadas.

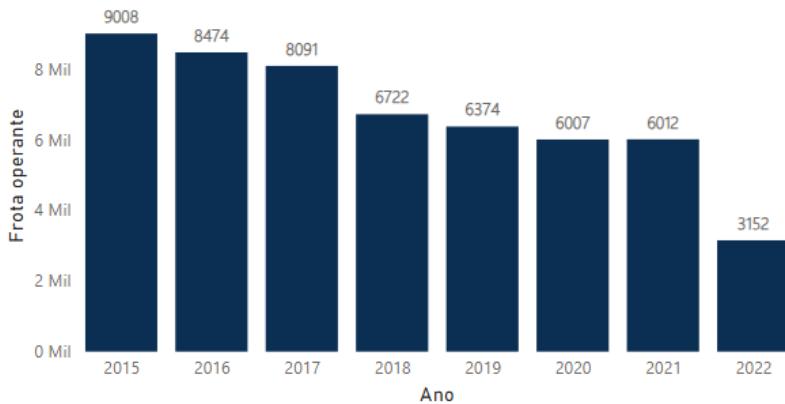


Fonte: Elaboração própria a partir de dados da SMTR.

De acordo com a prefeitura do Rio de Janeiro, em 2015, após um reajuste de 13,3%, a tarifa custava R\$3,40, e em 2016 reajustou 11,8% resultando em uma tarifa de R\$3,80. Contudo, devido a duas decisões judiciais, primeiramente, em agosto de 2017, a tarifa foi reduzida para R\$3,60 e posteriormente, em novembro de 2017, a tarifa passou a custar R\$3,40. As decisões judiciais revogaram o reajuste da tarifa em 2015, que foi permitido pela prefeitura mediante uma meta de instalar ar-condicionado em toda a frota em circulação e a mesma não foi cumprida (BAZANI, 2018b).

Acrescenta-se a esse cenário, a redução da frota operante no município desde 2015, como pode ser observado na Figura 34 que apresenta a frota operante de acordo com dados disponibilizados pelo Data.Rio(2023b). Em 2018, houve uma redução de 16,92% da média anual da frota operante. De acordo com o Rio Ônibus, sindicato das empresas de ônibus da cidade do Rio de Janeiro, a variação da frota operante observada em 2022 é atribuída à adoção de uma nova metodologia pelo sindicato. Essa metodologia considera a média da contagem dos veículos monitorados em dias úteis dos dois últimos meses do ano, reflexo da mudança na determinação da operação por ônibus da cidade do Rio de Janeiro a partir de junho de 2022, que resultou em uma redução das linhas operantes do sistema.

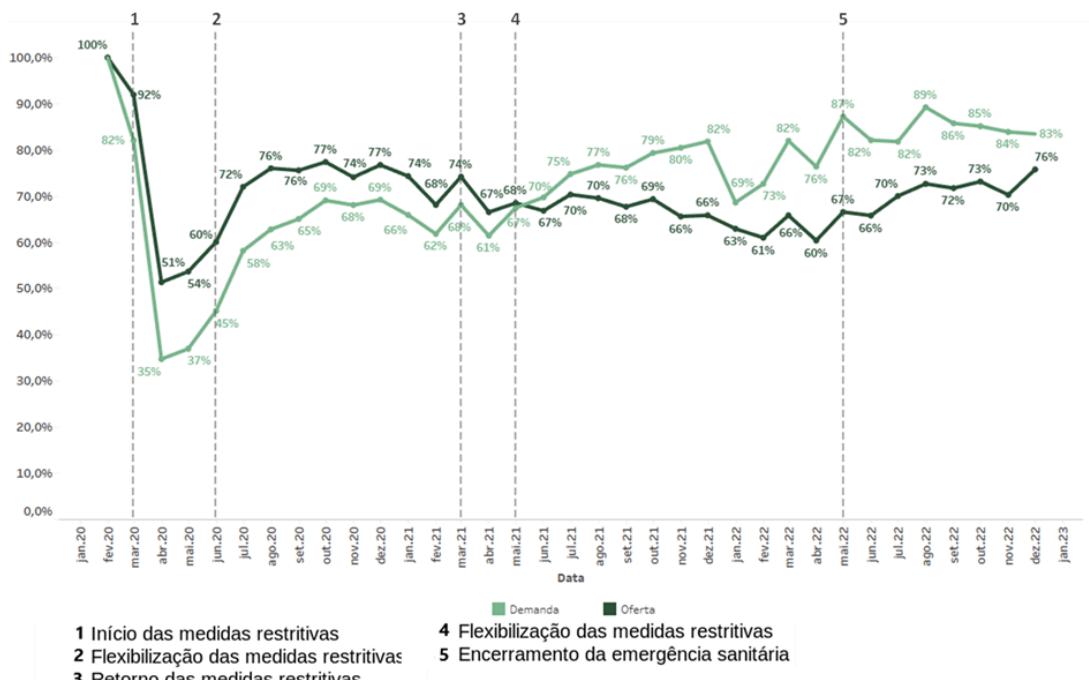
Figura 34 - Média anual da frota operante entre 2015 a 2022.



Fonte: Elaboração própria a partir de dados do Data.Rio.

Entre março de 2020 a dezembro de 2022, o comportamento da demanda e da oferta apresentou flutuações significativas, com momentos distintos caracterizados por variações tanto positivas quanto negativas em ambas as variáveis. A Figura 35 apresenta a variação percentual da demanda, passageiros transportados, e da oferta, viagens realizadas, em comparação aos valores registrados em fevereiro de 2020. Além disso, nessa figura são ilustrados os marcos temporais referentes às medidas restritivas de acordo com os decretos municipais relacionados ao enfrentamento do COVID-19, obtidos através do portal da Prefeitura do Rio de Janeiro.

Figura 35- Variação percentual mensal da demanda e da oferta em relação a fevereiro de 2020.



Fonte: Elaboração própria a partir de dados da SMTR.

Uma redução substancial do número de passageiros transportados ocorreu nos meses de março e abril de 2020, tendo esse último mês registrado uma queda de 65%, enquanto o nível de oferta foi reduzido em 49% no mesmo mês. Nos meses de junho de 2020 a outubro de 2020, verificou-se uma lenta recuperação, atingindo em outubro 69% da demanda e 77% da oferta. Essa recuperação do número de passageiros pode ser associada à flexibilização das medidas restritivas a partir de junho de 2020, que através do decreto municipal estabeleceu uma retomada gradual de algumas atividades e determinou o plano de retomada do município.

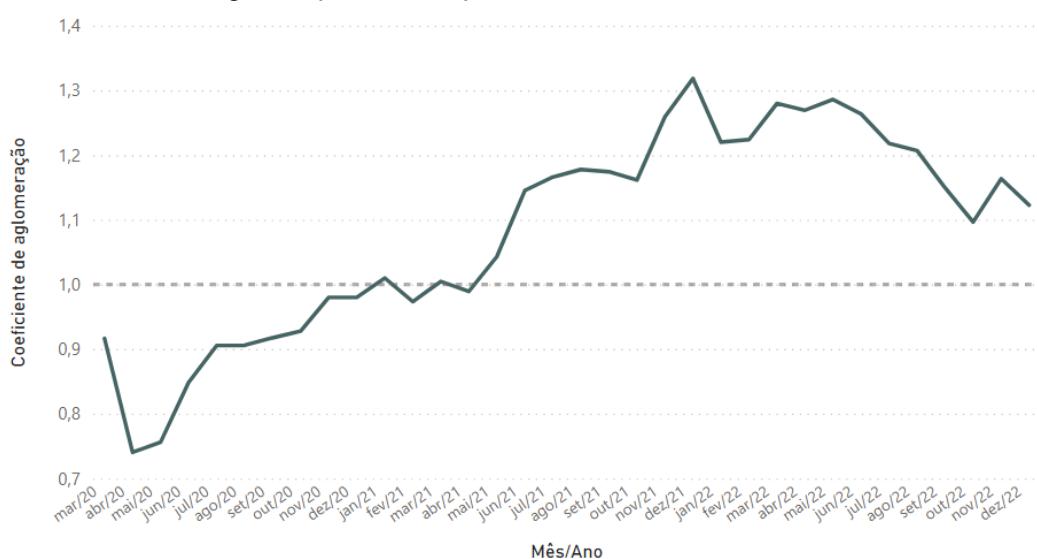
O Painel Rio Covid-19, disponibilizado pelo Data.Rio (2023c), revela um aumento do número de casos em novembro de 2020, assim como o número de óbitos. Segundo Freitas *et al.* (2022), nos meses de novembro e dezembro de 2022, período das comemorações de final de ano, juntamente com a flexibilização das medidas restritivas levaram a rápida transmissão da variante Gama que ocasionou uma elevação do número de casos e óbitos de março a junho de 2021. Nesse contexto, a prefeitura do Rio promulgou, em março de 2021, um decreto que ampliou as medidas de restrição devido ao aparecimento dessa nova variante. Com isso, em abril de 2020 houve uma redução de 39% da demanda acompanhada por uma redução de 33% da oferta.

A campanha de vacinação contra a COVID-19 no município do Rio de Janeiro iniciou em janeiro de 2021, e ao longo dos meses, progrediu conforme a disponibilidade de doses, priorizando os grupos prioritários, contribuindo para a redução de casos e óbitos. Nesse cenário, foram publicados dois decretos flexibilizando algumas medidas, primeiro no início de abril de 2021, autorizando o funcionamento de bares, lanchonetes, restaurantes, museus, bibliotecas, cinemas, teatros, entre outros locais de lazer e recreação com horários restritos, assim como o funcionamento de creches, escolas e estabelecimentos de ensino. Segundo, no final de abril de 2021, autorizando o retorno às atividades presenciais dos servidores e empregados públicos. A partir de maio de 2021, observa-se uma recuperação da demanda entre 67% a 82% até dezembro de 2021, no entanto a oferta apresenta um comportamento antagônico, reduzindo seu nível de 33% a 40% no mesmo período. Esse desequilíbrio entre a demanda e a oferta, em meio a uma emergência de saúde pública, possivelmente comprometeu a segurança sanitária dos passageiros, não garantindo o distanciamento necessário no interior dos ônibus.

Analogamente à abordagem desenvolvida pelo Carneiro *et al.* (2022), o coeficiente de aglomeração foi calculado no período pandêmico. Inicialmente, a quantidade de passageiros por viagem foi calculada para os meses de março de 2020 a dezembro de 2022. Posteriormente, o coeficiente de aglomeração foi obtido dividindo o cálculo anterior de cada

mês pela quantidade de passageiros por viagem referente ao mesmo mês do ano de 2019. O resultado é ilustrado na Figura 36. De acordo com os autores, um coeficiente de aglomeração superior a 1 indica um aumento da aglomeração nos ônibus durante o período em relação ao período pré-pandemia, enquanto inferior a 1 indica que o número de pessoas nas viagens não excedeu os valores do período pré-pandemia. Observa-se que a partir de maio de 2021, o coeficiente permaneceu acima de 1 até dezembro de 2022, indicando uma persistente tendência de maior aglomeração nos ônibus durante esse período, em relação ao período anterior à pandemia.

Figura 36 - Coeficiente de aglomeração entre março de 2020 a dezembro de 2022.



Fonte: Elaboração própria.

Em dezembro de 2021, iniciou uma nova onda epidemiológica da doença no país com a variante Ômicron, coincidindo com as comemorações de final de ano e a evolução da flexibilização das medidas restritivas segundo a Freitas *et al.* (2022). Ademais, foi registrado o maior número de casos da doença no município do Rio de Janeiro em janeiro de 2022, e consequentemente elevou o número de óbitos. Nesse contexto, o número de passageiros reduziu novamente e a oferta teve uma pequena oscilação negativa.

A partir da declaração do encerramento da emergência sanitária pelo Ministério da Saúde em maio de 2022, observa-se uma recuperação expressiva da demanda, atingindo seu máximo em agosto de 2022 com uma recuperação de 89%. A nível de oferta também aumentou, apresentando uma recuperação de 76% em dezembro de 2022.

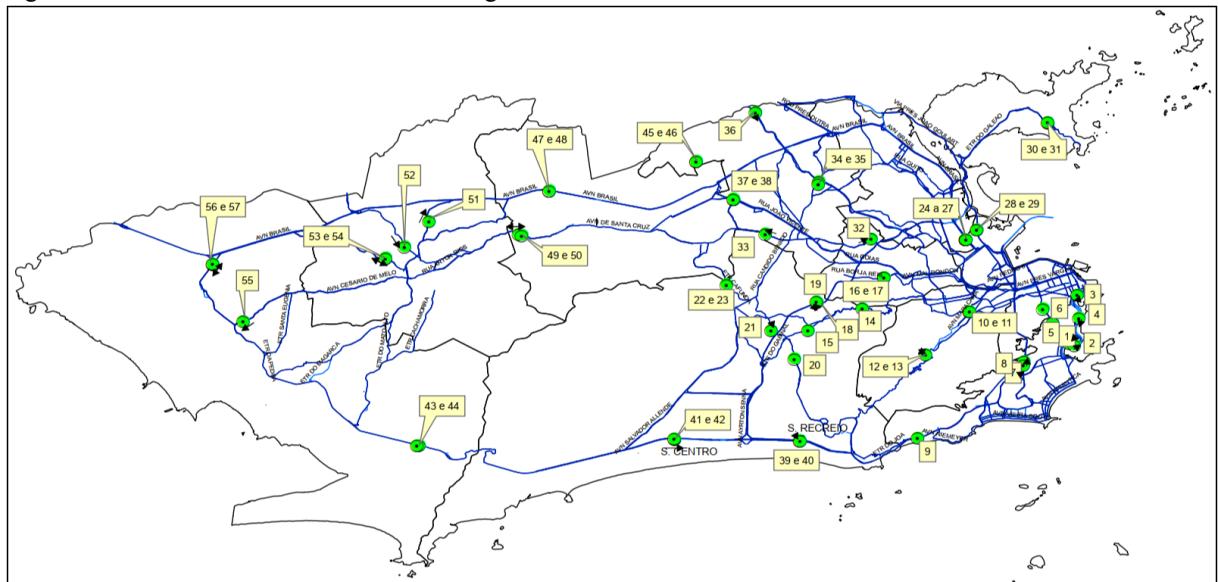
A prefeitura da cidade do Rio de Janeiro, por meio do pagamento de subsídio aos consórcios de ônibus a partir de junho de 2022, acordou a manutenção da tarifa de ônibus, a

regularização das linhas, a retomada das linhas inoperantes e o aumento da frota de ônibus circulante. O subsídio é pago de acordo com a quantidade de quilômetros percorridos pelos ônibus. Desde o segundo semestre de 2022, observa-se uma tendência ascendente na quantidade de viagens realizadas e de quilômetros percorridos. O incremento no número de passageiros e a concessão de subsídio às empresas de ônibus representam uma oportunidade de mitigar os impactos negativos ocasionados pela pandemia e fortalecer o sistema de transporte público por ônibus.

4.4 INDICADOR GLOBAL DE VOLUME VEICULAR (IGVOL)

O IGVOL é obtido por meio do monitoramento de tráfego em 57 vias na cidade do Rio de Janeiro, conforme indicado na Figura 37. O valor mensal do indicador é obtido a partir da soma dos fluxos médios registrados nessas vias. A CET-Rio faz uma ressalva nos relatórios que disponibilizam com os dados do indicador, informando que os dados de algumas vias podem conter inconsistência devido a obras ou falta de informações.

Figura 37 - Vias com monitoramento de tráfego.

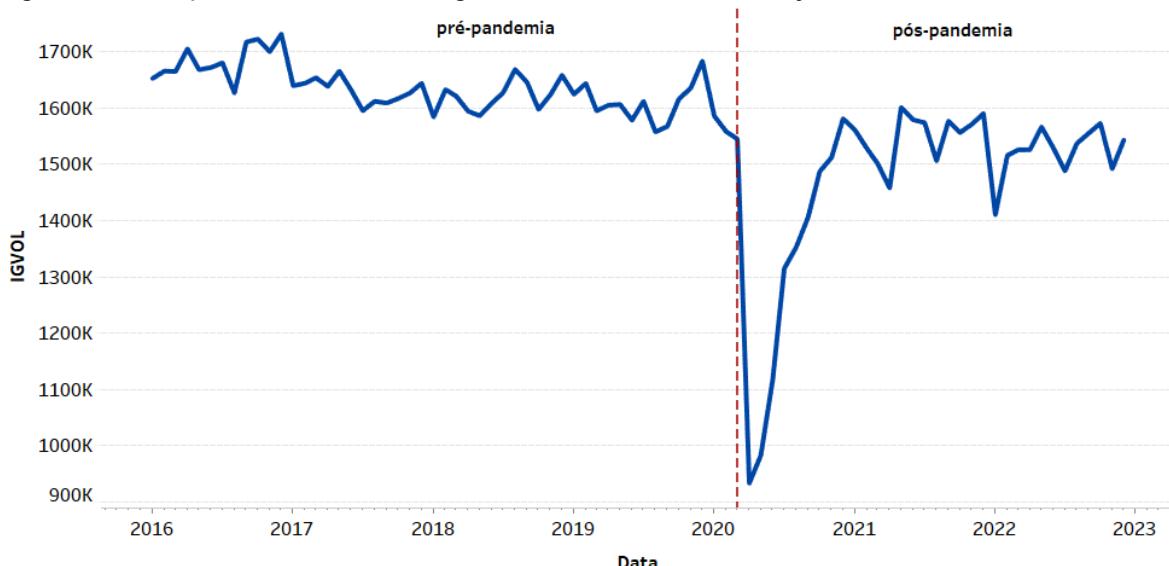


Fonte: CET-Rio (2022)

A evolução mensal do IGVOL do período de janeiro de 2016 a dezembro de 2022 é ilustrada na Figura 38. No período pré-pandemia, percebe-se que o fluxo de veículos apresentou um comportamento decrescente e flutuações mensais. O mês de dezembro destaca-se com o maior valor médio do fluxo de veículos, possivelmente devido ao aumento na movimentação nas vias durante os feriados do final do ano. Por outro lado, os meses de

janeiro e julho apresentaram os menores fluxos, o que pode estar relacionado ao período de férias escolares.

Figura 38 - Evolução mensal do indicador global de volume veicular entre janeiro de 2016 a dezembro de 2022.



Fonte: Elaboração própria a partir de dados da CET-Rio.

Em março de 2020, com a adoção das medidas para o enfrentamento da pandemia, o fluxo de veículos reduziu apenas 0,8% quando comparado ao mês anterior, contudo, em abril de 2020, ocorreu uma redução significativa do tráfego de veículos, representando uma diminuição de 39,6% em relação ao mês de março de 2020. Isso pode estar associado à ampliação das medidas que ocorreram a partir do final do mês de março. Portanto, esse mês foi caracterizado pelo menor valor do IGVOL em todo o período analisado. A partir deste mês, observa-se um aumento gradual do tráfego veicular, acompanhado por variações de queda e aumento do indicador ao longo dos meses. Essas flutuações podem ser atribuídas às medidas restritivas que foram flexibilizadas e posteriormente reforçadas durante a evolução da pandemia.

A média anual do fluxo de veículos e a variação percentual em relação ao ano anterior entre os anos de 2016 a 2022 são apresentados na Tabela 13. A tendência negativa observada na série temporal na pré-pandemia é confirmada pela redução consecutiva do volume de tráfego nos anos de 2017 a 2019. Em 2020, diante da situação de emergência enfrentada pelo município que resultou no fechamento e reabertura do comércio, indústrias e serviços ao longo desse ano, reduziu o número de veículos nas ruas. Apesar do notável aumento do fluxo de veículos no ano de 2021, o indicador não atingiu a média dos anos anteriores. Além disso,

o ano seguinte apresentou uma pequena contração do fluxo, sugerindo a possibilidade da continuação da tendência negativa observada no período anterior.

Tabela 13 - Indicador global de volume veicular e variação percentual.

Ano	IGVOL (K)	Diferença (%)
2016	1683,90	
2017	1631,42	-3,12
2018	1620,70	-0,66
2019	1610,42	-0,63
2020	1364,74	-15,26
2021	1550,24	13,59
2022	1521,82	-1,83

Fonte: Elaboração própria a partir de dados da CET-Rio.

Algumas medidas descritivas da série no período pré-pandemia e pós-pandemia são apresentadas na Tabela 14. A média do fluxo de veículos era 1634,0 antes da pandemia, enquanto no período pandêmico a média diminui para 1473,5, representando uma redução de 9,86% em comparação ao período anterior. O maior fluxo de veículos foi registrado em dezembro de 2016, com 1731,5, já o menor em agosto de 2019, com 1557,5, no período pré-pandemia. Enquanto, no período pós-pandemia, os meses que apresentaram o maior e o menor indicador foram maio de 2021 e abril de 2020, respectivamente, com 1601,0 e 933,3.

Tabela 14 - Estatísticas descritivas do indicador global de volume veicular.

Estatísticas	Pré-pandemia	Pós-pandemia
Mínimo	1557,5	933,3
1º Quartil	1606,9	1487,3
2º Quartil	1629,4	1527,0
Média	1634,0	1473,5
3º Quartil	1663,3	1565,0
Máximo	1731,5	1601,0

Fonte: Elaboração própria a partir de dados da CET-Rio.

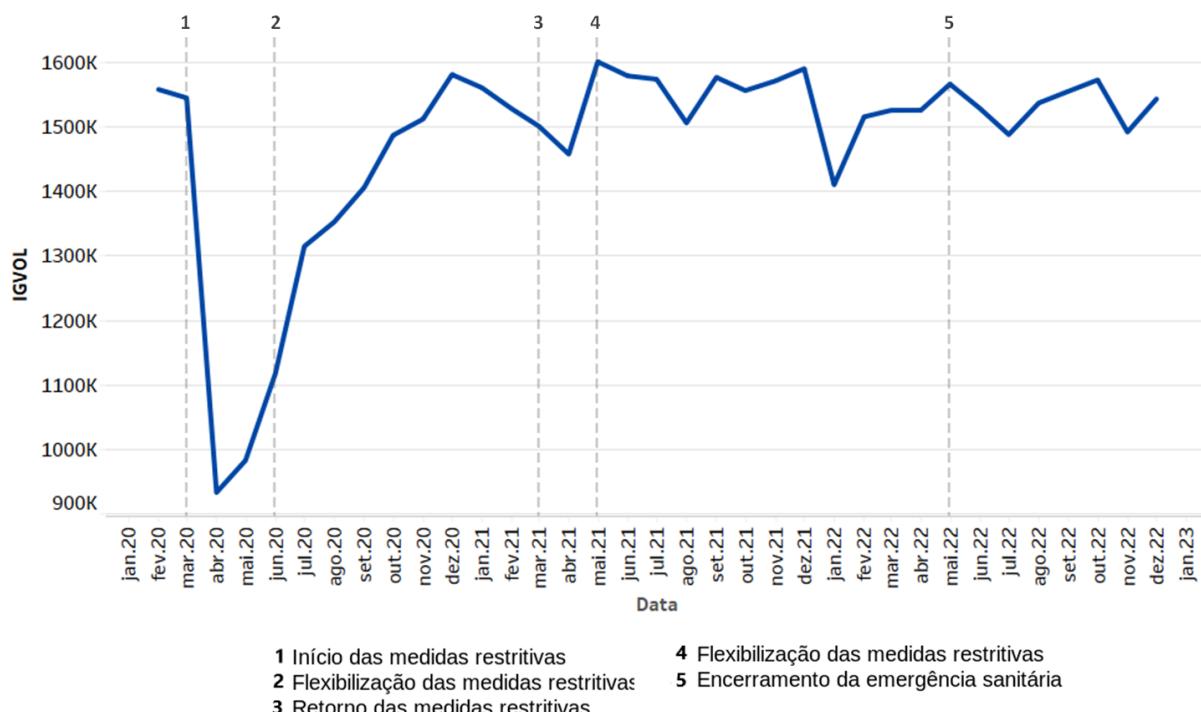
No período de março de 2020 a dezembro de 2022, foram identificadas flutuações significativas no fluxo de veículos, destacando momentos distintos caracterizados por variações positivas e negativas. A Figura 39 ilustra o IGVOL ao longo desse intervalo,

evidenciando os marcos temporais vinculados às medidas restritivas estabelecidas pelos decretos municipais no contexto do enfrentamento da COVID-19 na cidade do Rio de Janeiro.

No mês subsequente ao início da implementação das medidas visando conter a propagação do vírus, observou-se a queda abrupta do número de veículos em circulação, seguida por uma recuperação gradual nos meses seguintes, com uma recuperação de 84,4% no mês posterior a flexibilização das medidas em relação ao indicador observado em fevereiro de 2020. Em dezembro de 2020, o indicador registrou, pela primeira vez, um valor próximo ao observado no mês que antecedeu o início da pandemia. Conforme esperado pelo comportamento sazonal do indicador, nos meses de janeiro e fevereiro de 2021, o tráfego de veículos reduziu novamente, persistindo em declínio até abril de 2021, devido à retomada das medidas restritivas em resposta ao aumento de casos e óbitos.

A partir da flexibilização das medidas em maio de 2021, o indicador apresentou flutuações, sendo dezembro de 2021 e 2022 os meses com os maiores indicadores, enquanto janeiro de 2021 registrou o menor indicador. Essas variações podem ser atribuídas a fatores sazonais, como o aumento da circulação de veículos durante as celebrações de final de ano e a redução durante o período de férias. Apesar da recuperação em relação ao tráfego observado em fevereiro de 2020, o indicador não alcançou a média do IGVOL do período pré-pandemia em nenhum mês desde o início da crise sanitária.

Figura 39 - Evolução mensal do indicador global de volume veicular entre março de 2020 a dezembro de 2022.



Fonte: Elaboração própria a partir de dados da CET-Rio.

Diante desse contexto, evidencia-se que os indivíduos têm optado por alternativas ao transporte público coletivo, uma vez que se nota uma retomada do volume de tráfego, atingindo valores 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 pequena diferença no fluxo de veículos entre os períodos pós-pandemia e pré-pandemia, apresentando uma redução na média mensal de apenas 9,8%. Em contraste, a média mensal do número de passageiros transportados no período pós-pandemia apresentou uma queda mais acentuada, reduzindo 48,9% em relação ao período anterior à pandemia.

4.5 FROTA DE VEÍCULOS INDIVIDUAIS

Nos últimos anos, os padrões de mobilidade urbana são caracterizados pela queda da demanda do transporte público e aumento do uso do transporte individual. Percebe-se isso pela redução do número de passageiros no transporte público por ônibus e aumento da frota de veículos individuais motorizados. A variedade de opções de financiamento para a aquisição de veículos no Brasil, associada a tradição cultural que atribui a posse de um carro a sensação de mobilidade e liberdade, contribuem significativamente para o aumento das vendas e, consequentemente, para a presença desses veículos nas ruas (RAMIS E SANTOS, 2012).

De acordo com os dados do DETRAN-RJ, e considerando a frota de cada ano como a frota do mês de dezembro do ano, a Tabela 15 apresenta a frota dos veículos individuais e a porcentagem de cada um na frota do município do Rio de Janeiro. Observa-se que entre os anos de 2015 a 2022 a frota de automóveis e motocicletas aumentou continuamente, e representavam, em média, 72,79% e 10,89% da frota municipal respectivamente. Comparando-se a frota do ano de 2015 com a do ano de 2022, verifica-se um aumento de 7,5% do número de automóveis e 29,9% do número de motocicletas, além disso nota-se que a proporção de motos aumentou durante esses anos e a proporção de carros diminuiu.

Tabela 15 - Frota de automóveis e motocicletas no município do Rio de Janeiro

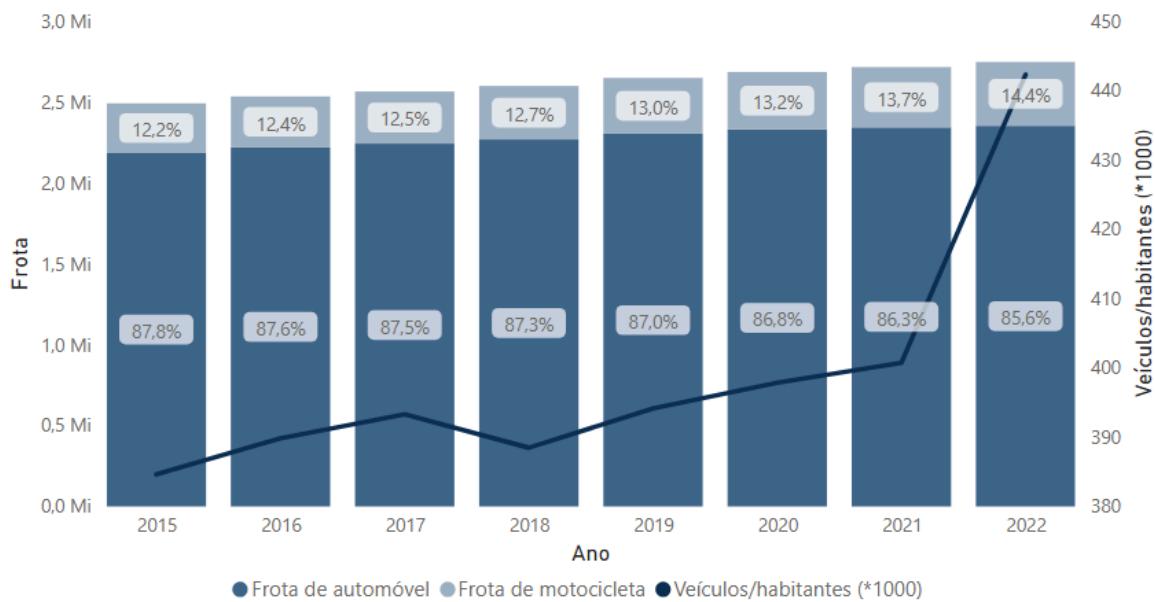
Ano	Automóvel	Automóvel na frota municipal (%)	Motocicleta	Motocicleta na frota municipal (%)
2015	2.187.098	74,05	303.998	10,29
2016	2.219.689	73,70	313.834	10,42
2017	2.242.666	73,50	321.639	10,54
2018	2.268.290	73,21	330.139	10,66
2019	2.303.693	72,79	344.441	10,88
2020	2.329.881	72,49	354.764	11,04
2021	2.342.405	71,74	372.561	11,41
2022	2.352.114	70,84	394.851	11,89

Fonte: Elaboração própria a partir de dados do DETRAN-RJ.

Apesar do aumento da participação das motos na composição da frota municipal, o carro é o veículo predominante da frota, como é possível observar na Figura 40, que apresenta a divisão da composição da frota de veículos individuais incluindo automóveis e motocicletas. Na mesma figura também é apresentada a taxa de motorização, a razão entre o número de veículos e o número de habitantes multiplicado por 1000, sendo considerado para os anos de 2015 a 2021 a estimativa da população e no ano de 2022 a população divulgada no censo de 2022. Esse indicador expressa a dimensão das frotas e do grau de motorização de uma determinada região, sendo fundamental para compreender a influência da quantidade de veículos nas características do sistema de transportes e dos padrões de viagens (LOPES, 2005).

A taxa de motorização do município do Rio de Janeiro, entre o período de 2015 a 2022, apresentou um comportamento crescente. No ano de 2015, eram aproximadamente 385 veículos por 1000 habitantes, já no ano de 2022, eram aproximadamente 442 veículos por 1000 habitantes. Nesse mesmo período, observou-se a redução da frota operante de ônibus, evidenciado a predominância do transporte individual em detrimento do transporte público.

Figura 40 - Frota de automóveis e motocicletas e taxa de motorização.



Fonte: Elaboração própria a partir de dados do DETRAN-RJ.

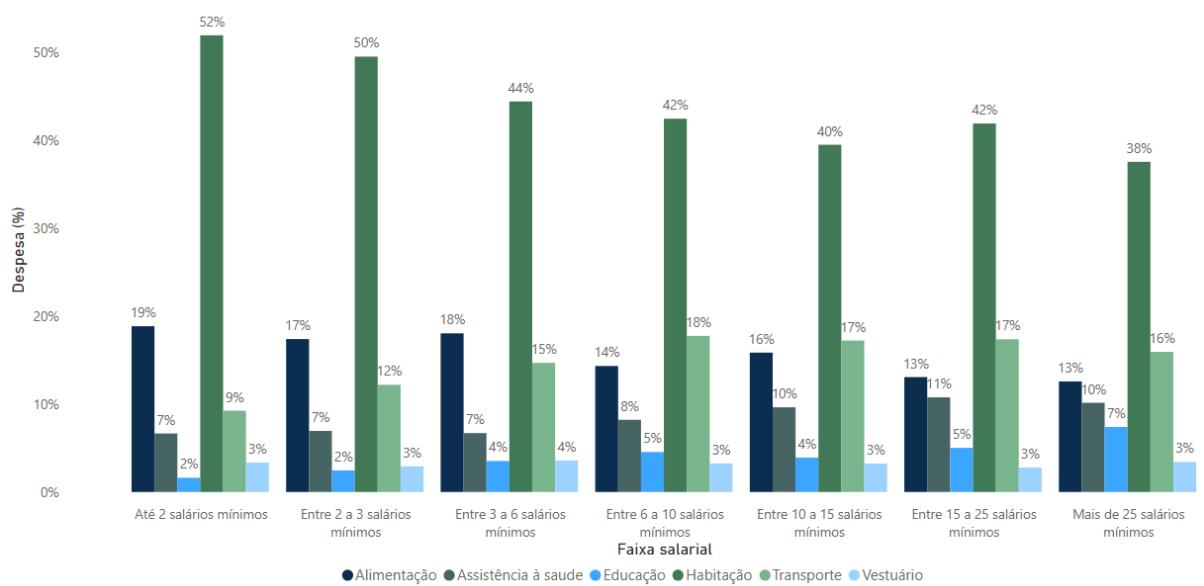
A NTU (2017) realizou uma análise retrospectiva dos acontecimentos que levaram a esse cenário atual. Iniciou-se com o crescimento urbano desordenado e espraiamento urbano que juntamente com a falta de investimento de mobilidade urbana resultou em deslocamentos maiores em distância e tempo. Depois, surgiram as políticas de incentivo ao transporte individual, como a isenção de impostos e o aumento da gasolina inferior ao do diesel, tornando o veículo individual mais atrativo e contribuindo para o aumento dos congestionamentos. Diante da redução da demanda do transporte público, as operadoras reduziram a oferta do serviço na tentativa de reequilibrar as contas. Contudo, isso levou ao aumento da espera, comprometendo a qualidade e competitividade do sistema.

Neste contexto de crescimento da quantidade de veículos motorizados e redução da utilização do transporte público, observa-se um impacto direto no aumento do tráfego, contribuindo consequentemente para um incremento no tempo de deslocamento e prejudicando a qualidade de vida urbana. De acordo com a pesquisa desenvolvida por Pereira, R *et al.* (2021), o tempo de viagem no deslocamento entre casa e trabalho na região metropolitana do Rio de Janeiro era 42 minutos em 2001 e aumentou para 48 minutos em 2015. Outro destaque da pesquisa foi o tempo médio de viagem segundo a renda domiciliar *per capita*, que demonstrou que as pessoas de renda maior estão gastando mais tempo no deslocamento casa-trabalho, o que possivelmente pode ser associado ao aumento dos congestionamentos. Por outro lado, o aumento do tempo de deslocamento das pessoas de

renda menor, pode ser associado além do aumento dos congestionamentos a redução da oferta de transporte público.

A Pesquisa de Orçamentos Familiares (POF) realizada pelo IBGE apresenta o valor e a composição dos gastos médio mensal familiar de acordo com os grupos socioeconômicos. A Figura 41 ilustra os principais gastos e a distribuição desses por classes de rendimento do estado do Rio de Janeiro de acordo com a POF 2017-2018. O gráfico evidencia que as despesas média mensal com transporte, incluindo gastos com transporte urbano e gastos com combustível e manutenção de veículos próprios, representam em média 12% para as famílias com renda até 6 salários mínimos e em média 17% para as famílias com renda superior a 6 salários mínimos. Ademais, é possível observar que as famílias com rendimento superior a 6 salários mínimos comprometem mais sua renda com despesas de transporte do que despesas de alimentação.

Figura 41 - Distribuição das principais despesas de consumo por classes de rendimento



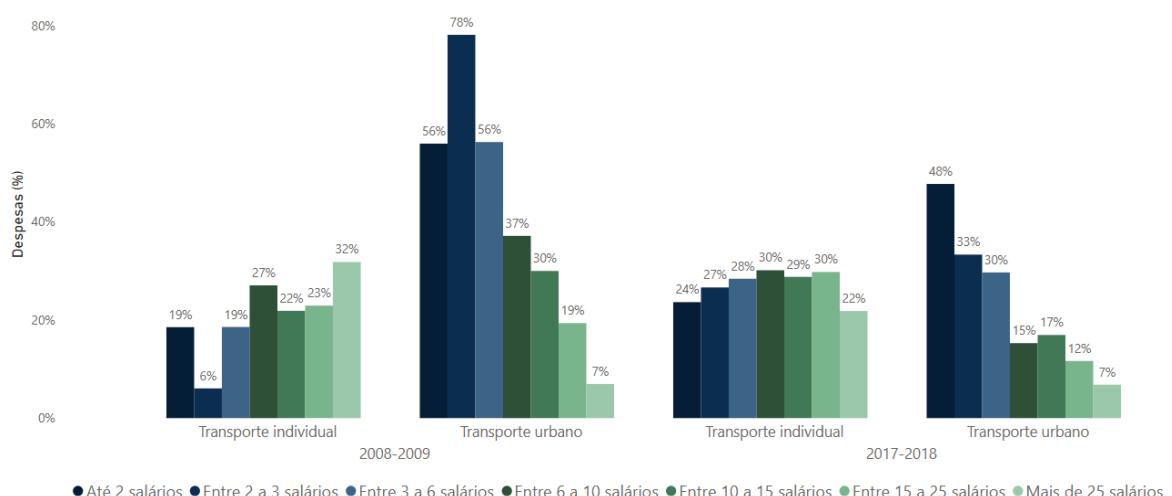
Fonte: Elaboração própria de acordo com a Pesquisa de Orçamentos Familiares 2017-2018.

É notável o peso das despesas com transporte no orçamento das famílias, contudo o perfil desse gasto alterou-se ao longo dos anos. Examinando a proporção do gasto com transporte urbano e com transporte individual, que inclui despesas com combustível e manutenção dos veículos próprios, da despesa de transportes a partir da POF 2008-2009 e POF 2017-2018, apresentados na Figura 42, observa-se que o gasto com transporte urbano diminuiu e os gastos com transporte individual aumentaram comprando as despesas do ano de 2008 com o ano de 2018.

Em ambas as pesquisas, constatou-se que as famílias com renda mensal de até 6 salários mínimos eram as que mais destinavam parte de seu orçamento para o transporte urbano. Contudo, essas famílias diminuíram seus gastos com transporte urbano e aumentaram as despesas com combustível e manutenção dos veículos próprios. Além disso, a última pesquisa mostrou que essa mesma faixa de rendimento comprometeu mais seu orçamento com a aquisição de veículos.

A mesma tendência de mudança no perfil de despesas foi observada entre as pessoas de renda mais alta. Essas famílias, que já utilizavam o transporte público com menor frequência, reduziram ainda mais essa despesa e aumentaram os gastos com veículos próprios. Esses dados sugerem a alteração real da preferência pelo uso do transporte individual em detrimento ao transporte coletivo, que possivelmente pode ser associado ao aumento de renda da população e a redução da oferta do transporte público.

Figura 42 - Proporção dos gastos com transporte urbano e transporte individual nas despesas de transporte por classes de rendimento.



Fonte: Elaboração própria de acordo com a Pesquisa de Orçamentos Familiares 2008-2009 e 2017-2018.

Lopes (2005) destaca em seu trabalho uma citação de Cristina Baddini¹, apresentada a seguir, em uma entrevista concedida à FETRANSPO, na qual ressalta o aumento da taxa de motorização e suas implicações na mobilidade da população, enfatizando a necessidade de investimento no transporte público. No entanto, os dados indicam que, mesmo quase duas décadas após essa citação, o cenário do transporte público não apresentou melhorias significativas. Nesse contexto, continua inalterado o ciclo vicioso caracterizado pelo aumento

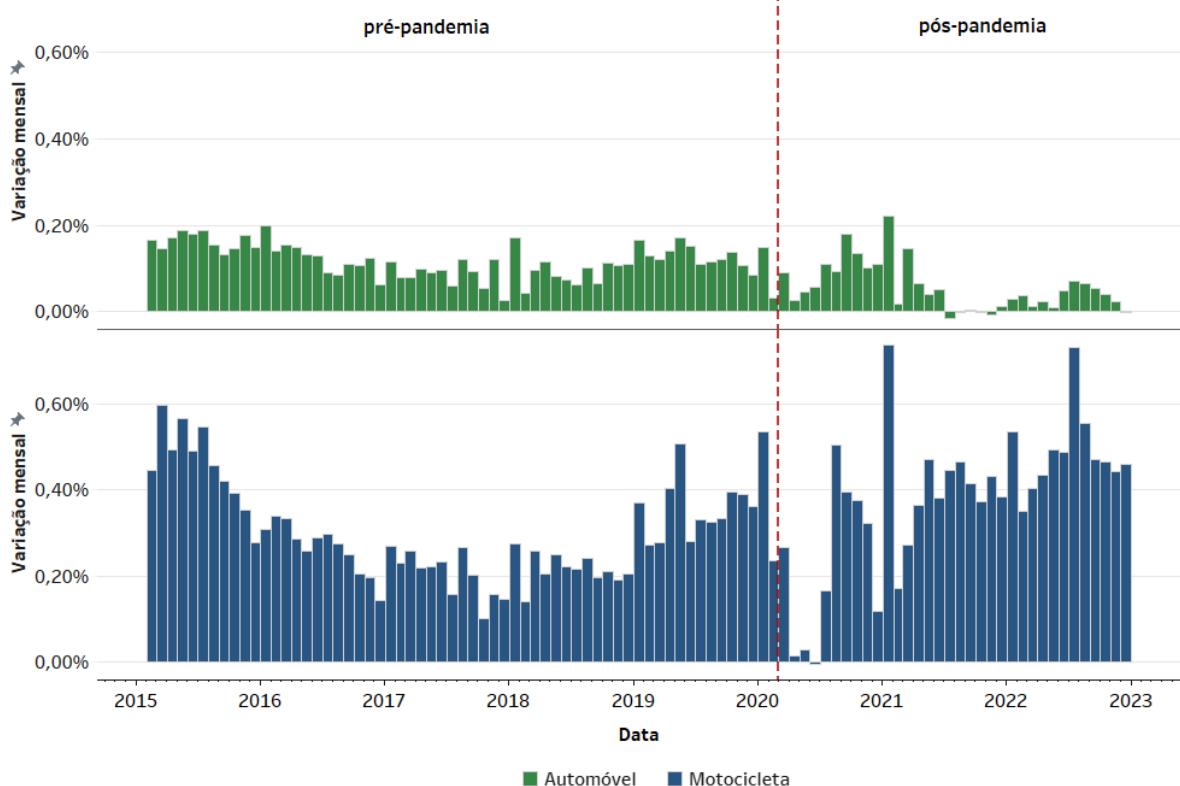
¹ Cristina Baddini, em 2005, era diretora adjunta da ANTP e de planejamento do Fórum nacional de Secretários de Transporte, assessora técnica da Diretoria de Gestão da SPTrans (São Paulo /SP) e membro da Associação de Transporte e Meio Ambiente.

dos congestionamentos devido a presença de mais veículos nas ruas, que resulta em maior tempo de deslocamento e na deterioração da qualidade do transporte coletivo, levando os usuários a optarem pelo transporte individual, ocasionando a redução das receitas e o aumento dos custos operacionais, culminando, consequentemente, no aumento das tarifas (STUMPF, 2018).

“É importante que os cidadãos cobrem dos candidatos um posicionamento sobre o transporte público” (...) “o crescimento exagerado do transporte individual, incentivado boa parte pela concessão de incentivos fiscais à indústria automobilística, nos últimos anos, só levou à perda de mobilidade da população de mais baixa renda” (...) “O uso do transporte individual não aumenta a mobilidade da população, ao contrário: as pessoas estão ficando mais tempo paradas dentro dos veículos. Em São Paulo, os congestionamentos chegaram a uma extensão de 120 quilômetros” (...) “depois de tantas administrações que investiram apenas nas aberturas de vias. Este tipo de mentalidade não cabe mais. É preciso um sistema de transporte público bom e barato, com ônibus mais confortáveis e rápidos (...)” precisamos entender que o uso exagerado do automóvel faz mal, gera desperdício de recursos e contribui para o aquecimento do planeta e a poluição do ar. O gasto com automóvel é de 20 a 30 vezes maior do que na cadeia de transporte público”.

Em 2020, a pandemia de COVID-19 gerou impactos para o transporte público por ônibus, com a redução da demanda e da oferta do serviço, assim como afetou o crescimento da frota de veículos individuais. A frota de automóveis e motocicletas permaneceu crescendo entre os anos de 2020 a 2022, no entanto o crescimento da frota de carros foi inferior ao da frota de motos, enquanto a primeira aumentou 2,10% entre 2019 a 2022, a segunda aumentou 14,64%. A Figura 43 expõe a variação mensal da frota de automóveis e motocicletas, na qual percebe-se tanto no período pré-pandemia como no pós-pandemia, o número de motos aumentou em proporções maiores do que o número de carros. No período pré-pandemia isso se intensificou, e verificou-se aumentos maiores da frota de motocicletas do que no período pós-pandemia, em 2021 e 2022, o aumento da frota foi de 5,02% e 5,98% respectivamente, contra um crescimento anual média de 3,17% nos anos do período pré-pandemia. Enquanto isso, a frota de carros registrou os menores crescimentos dos últimos anos. De acordo com Silva *et al.* (2011), o substancial aumento da frota de motocicletas no Brasil pode ser atribuído ao fato de que a frota, em 2000, era relativamente baixa, assim como a facilidade de aquisição, manutenção e baixo consumo de combustível, tornando-as uma opção mais acessível para pessoas de baixa renda.

Figura 43 - Variação mensal da frota de automóveis e motocicletas entre janeiro de 2015 a dezembro de 2022.



Fonte: Elaboração própria de acordo com o DETRAN-RJ.

Esse aumento contínuo da frota pode ser explicado pela predileção das pessoas em utilizar o transporte motorizado individual, possivelmente influenciadas pela qualidade do transporte público por ônibus. A redução no número de viagens ofertadas pelo sistema de transporte público por ônibus no município nos últimos anos, sugere 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.

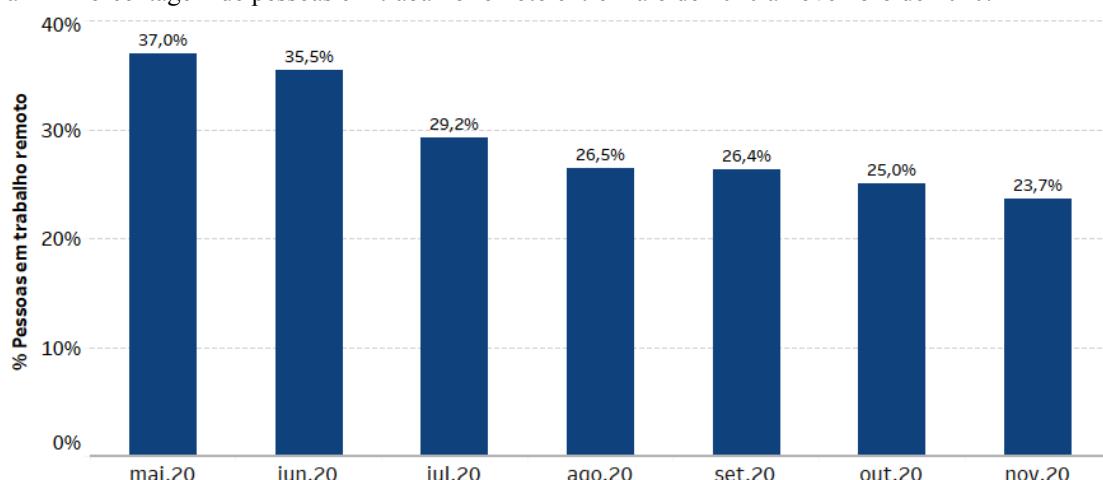
4.6 TRABALHO REMOTO

O trabalho remoto foi adotado como uma estratégia para controlar a disseminação do vírus e permitir a continuidade das atividades econômicas (BENAVIDES, 2021). A pesquisa PNAD COVID-19, realizada de maio a novembro de 2020, buscou monitorar os impactos da pandemia de COVID-19 no mercado de trabalho, fornecendo estimativas sobre a adesão ao teletrabalho no município do Rio de Janeiro. Os domicílios entrevistados permaneceram os

mesmos em todos os meses da pesquisa, garantindo uma compreensão da dinâmica do trabalho remoto ao longo da evolução da doença.

A Figura 44 exibe a porcentagem de entrevistados que adotaram o trabalho remoto. Nos meses de maio e junho, observou-se a maior proporção de pessoas exercendo essa prática, representando 37,0% e 35,5%, respectivamente, do total de pessoas ocupadas e não afastadas. Durante esse mesmo período, a demanda pelo transporte público por ônibus e o indicador IGVOL atingiram alguns dos valores mais baixos ao longo da pandemia. Nestes meses, a demanda do transporte público foi de 37% e 45% da registrada em fevereiro de 2020, enquanto o fluxo de veículos correspondeu a 63% e 72%, respectivamente, do observado no mesmo período de referência, reforçando a evidência da redução de movimentação das pessoas.

Figura 44 - Porcentagem de pessoas em trabalho remoto entre maio de 2020 a novembro de 2020.



Fonte: Elaboração própria a partir dos dados da PNAD COVID-19.

Nos meses subsequentes, com a flexibilização das medidas restritivas e a retomada gradual das atividades econômicas, a proporção de pessoas adotando o trabalho remoto apresentou uma diminuição. No último mês da pesquisa, em novembro de 2020, verificou-se que 23,7% das pessoas estavam exercendo suas atividades de forma remota. Nesse 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 Tabela 16 apresenta as características das pessoas em trabalho remoto durante esse período, considerando a média mensal por sexo, cor ou raça, escalaridade e faixa etária. Nota-se que 52,9% das pessoas em trabalho remoto eram mulheres, e predominantemente

brancas, correspondendo a 70,6%, enquanto pardas e pretas representavam 28,8%. Aproximadamente 79,9% das pessoas possuíam ensino superior completo. O grupo etário com a maior proporção de pessoas nessa modalidade de trabalho era entre 30 e 39 anos com 29,5%, seguido por aqueles entre 40 e 49 anos com 24,4%.

Tabela 16 - Perfil das pessoas em trabalho remoto entre maio de 2020 a novembro de 2020.

Característica		Percentual (%)
Sexo	Homem	47,1
	Mulher	52,9
Cor ou raça	Branca	70,6
	Parda	21,9
	Preta	6,9
Escolaridade	Fundamental incompleto	0,2
	Fundamental completo e médio incompleto	0,9
	Médio completo e superior incompleto	19,0
	Superior completo	79,9
Faixa etária	14 - 19	0,5
	20 - 29	14,5
	30 - 39	29,5
	40 - 49	24,4
	50 - 59	18,0
	60 - 59	10,7
	70 - 49	2,4
	80 ou mais	0,1

Fonte: Elaboração própria a partir dos dados da PNAD COVID-19.

Conforme os dados apresentados na Tabela 17 que exibe o tipo de atividade da empresa, o tipo de ocupação e a faixa de rendimento das pessoas em trabalho remoto, constata-se que 20,6% das empresas que mais adotaram o teletrabalho estavam vinculadas ao setor de educação, seguidas por organizações governamentais federais, estaduais e municipais, representando 12,4%. Em sequência, destacam-se empresas ligadas às atividades de advocacia, engenharia, publicidade e veterinária. Dentro dessas principais atividades, profissionais de nível superior, como advogados, engenheiros, contadores e jornalistas, assim

como professores, foram os que mais aderiram ao trabalho remoto, corroborando o perfil educacional identificado na análise das pessoas que trabalharam por essa modalidade.

Tabela 17 - Distribuição das pessoas em trabalho remoto por atividade, ocupação e rendimento.

Característica	Tipos	Percentual (%)
Atividade	Educação	20,6
	Administração pública	12,4
	Escritórios de advocacia, engenharia, publicidade e veterinária	9,8
	Informação e comunicação	8,0
	Saúde humana e assistência social	6,7
	Bancos, atividades financeiras e de seguros	6,4
	Outras	36,1
Ocupação	Profissão de nível superior	34,0
	Professor da educação infantil, de ensino fundamental, médio ou superior	14,5
	Técnico ou profissional de nível médio	8,3
	Diretor, gerente, cargo político ou comissionado	7,0
	Outros	37,0
Rendimento	0 - 1.600	20,6
	1.601 - 3.000	22,8
	3.001 - 10.000	43,7
	10.001 - 50.000	12,9
	50.001 - 100.000	0,1

Fonte: Elaboração própria a partir dos dados da PNAD COVID-19.

No que se refere ao rendimento desses profissionais, observa-se que 43,7% recebiam entre R\$3.001 a R\$10.000. Segundo os dados da Pesquisa de Orçamentos Familiares 2017-2019 na Figura 42 e considerando que o salário mínimo em 2020 era R\$1039,00, constatou-se que pessoas com rendimento entre 3 a 6 salários mínimos comprometiam 28% de seu orçamento com transporte individual e 30% com transporte urbano. Já aqueles com rendimento entre 6 a 10 salários mínimos destinavam 30% do orçamento para o uso de automóvel e apenas 15% para o transporte público. Esses números indicam que a maior parcela das pessoas que aderiram ao trabalho remoto utilizava predominantemente o

transporte individual, contribuindo para a não ultrapassagem do nível médio de fluxo de veículos observado no período pré-pandemia.

Por outro lado, além dos indivíduos da classe entre 3 a 10 salários que ainda utilizam mais o transporte urbano do que o individual, soma-se à predominante utilização do transporte público por parte dos 20,6% das pessoas que recebem até R\$1.600. Essas classes de rendimento configuram-se como as classes que mais despendem recursos na utilização do transporte urbano. Possivelmente, a ausência da necessidade de deslocamento casa-trabalho, influenciada pelo trabalho remoto, contribuiu para a redução da demanda dos ônibus nesse contexto.

A PNAD COVID-19 era a única pesquisa nacional que desempenhava o papel fundamental no acompanhamento do trabalho remoto no país. Entretanto, no 4º trimestre de 2022, um módulo sobre teletrabalho foi incorporado à Pesquisa Nacional por Amostra de Domicílios Contínua, apresentando estatísticas experimentais. O IBGE ressalta a natureza experimental dessas estatísticas, recomendando sua utilização com prudência, visto que estão em fase de teste e avaliação. A transição para a PNAD Contínua amplia as possibilidades de análises futuras sobre o trabalho remoto, permitindo uma compreensão mais abrangente das mudanças observadas durante a pandemia, avaliando se são de natureza transitória ou permanente.

Nessa pesquisa, o trabalho remoto foi definido como atividades realizadas fora do local de trabalho padrão, como domicílio, cafés e espaços abertos. O teletrabalho, uma subcategoria do trabalho remoto, foi delimitado como aquele que requer o uso de dispositivos eletrônicos para sua execução. Considerando essas definições e com o objetivo de analisar a proporção de pessoas que reduziram seus deslocamentos para o trabalho, assim como o perfil dessas pessoas, os resultados da pesquisa em relação ao teletrabalho realizado no domicílio são apresentados nas Tabelas 20 e 21.

De acordo com os resultados da pesquisa na Tabela 18, no estado do Rio de Janeiro, 11,5% e 9,7% do total de ocupados que não estavam afastados do trabalho realizaram trabalho remoto e teletrabalho no domicílio, respectivamente, valores acima do percentual nacional. O rendimento médio mensal desses indivíduos que realizaram teletrabalho no domicílio é de R\$7559.

Tabela 18 - Percentual das pessoas que realizaram trabalho, trabalho remoto e teletrabalho no domicílio.

Brasil e UF	Trabalho	Trabalho remoto	Teletrabalho
Brasil	15,6	9,0	7,3
Rio de Janeiro	19,0	11,5	9,7

Fonte: Elaboração própria a partir dos dados da PNAD Contínua.

Na Tabela 19 verifica-se que o perfil das pessoas que adotaram o teletrabalho no país em 2022 permanece inalterado em comparação com o observado em 2020. Nesse contexto, mulheres continuam a aderir mais a essa modalidade, assim como a predominância de indivíduos autodeclarados brancos. Além disso, persiste a prevalência da conclusão do ensino superior entre aqueles que realizam teletrabalho, assim como o destaque para pessoas na faixa etária entre 25 e 39 anos.

Tabela 19 - Perfil das pessoas que realizaram teletrabalho no domicílio em 2022.

Característica	Tipo	Percentual (%)
Sexo	Homem	6,4
	Mulher	8,4
Cor ou raça	Branca	10,5
	Parda	4,5
	Preta	4,8
Escolaridade	Sem instrução e fundamental incompleto	0,5
	Fundamental completo e médio incompleto	1,2
	Médio completo e superior incompleto	4,5
	Superior completo	22,5
Faixa etária	14 - 17	1,1
	18 - 24	4,9
	25 - 39	9,2
	40 - 59	6,6
	60 ou mais	5,7

Fonte: Elaboração própria a partir dos dados da PNAD Contínua.

Os dados por grupamento de atividade indicam que 24,5% das pessoas que praticavam teletrabalho no domicílio estavam vinculadas a empresas relacionadas a informações, comunicação, atividades financeiras, imobiliárias, profissionais e administrativas. Além disso, 10,8% desses teletrabalhadores estavam inseridos no setor

público, abrangendo administração, defesa, seguridade social, educação, saúde humana e serviços sociais. Em termos ocupacionais, constatou-se que 25,3% estavam em cargos de direção e gerência, enquanto 27,3% desempenhavam funções relacionadas às ciências e intelectuais.

A PNAD COVID-19 evidenciou que o trabalho remoto foi adotado durante a pandemia, com um declínio gradual no percentual de pessoas que aderiram a essa modalidade até o último mês da pesquisa. A PNAD Contínua complementa essas informações ao revelar que ainda existem pessoas que continuam a adotar essa prática. A participação mais expressiva do teletrabalho na dinâmica do mercado de trabalho não apenas representa uma adaptação ao contexto pandêmico, mas também sinaliza mudanças duradouras na maneira como as pessoas se deslocam.

Neste capítulo, foram apresentadas as estimativas do impacto da pandemia de COVID-19 no número de passageiros transportados e na quantidade de viagens realizadas através da análise de séries temporais interrompidas. Evidenciou-se a expressiva redução na demanda e na oferta do transporte público por ônibus, analisando o comportamento dessas variáveis ao longo da pandemia, marcada pelas adaptações das medidas de isolamento, ajustando-se conforme a evolução da doença na cidade. Também foi explorado o comportamento do tráfego de veículos durante esse período, observando uma recuperação mais rápida e expressiva em comparação com a demanda do transporte público.. Isso reforça a preferência pelo uso do transporte individual, evidenciada pelo aumento contínuo da frota de automóveis e motocicletas, juntamente com o crescimento dos gastos relacionados a combustíveis e aquisição de veículos. Acrescenta-se ainda o impacto do trabalho remoto como um fator contribuinte para os novos padrões de mobilidade urbana.

5 CONSIDERAÇÕES FINAIS

O sistema de transporte público por ônibus enfrentou desafios significativos devido à pandemia de COVID-19, sofrendo uma substancial redução da demanda. As medidas de distanciamento social, implementadas para conter a propagação do vírus, resultaram na redução da circulação das pessoas, impactando o sistema de ônibus. Os indicadores de desempenho operacional revelaram um cenário preocupante, com expressivas reduções da demanda e oferta nas cidades brasileiras.

A mudança global nos padrões de deslocamento durante a pandemia, evidenciada na literatura, incluiu um aumento no uso de transporte individual em detrimento do transporte público. Além disso, a transição para atividades remotas, tanto escolares quanto econômicas, contribuiu para a diminuição dos deslocamentos. Compreender e avaliar esses efeitos é fundamental para o planejamento urbano, destacando a necessidade de um sistema de transporte público eficiente para a mobilidade urbana e o funcionamento das cidades.

O desenvolvimento deste estudo teve como objetivo avaliar os efeitos da pandemia no transporte público por ônibus no município do Rio de Janeiro, assim como analisar o uso do transporte individual e a adoção do trabalho remoto. A análise de séries temporais interrompidas foi empregada, utilizando os modelos de regressão segmentada e ARIMA, sendo este último o que mostrou o melhor ajuste para a série de demanda e oferta do transporte público por ônibus.

A série temporal da quantidade de passageiros transportados apresentou uma tendência decrescente pré-pandemia, associada à redução da demanda, e uma tendência ascendente pós-pandemia, refletindo a retomada gradual. O modelo SARIMA(0,1,1)(2,0,0)12 demonstrou ser eficaz na representação dessa série, permitindo estimar uma perda de 29,47% de passageiros entre março de 2020 a dezembro de 2022. Esta queda acentuada, aliada à dependência da tarifa como principal fonte de receita, expôs ainda mais a fragilidade do modelo de financiamento do transporte público. A partir de maio de 2022, foi implementado o pagamento de subsídios às empresas de ônibus municipais, buscando preservar o valor da tarifa e promover melhorias nos ônibus.

A série temporal da quantidade de viagens realizadas revelou uma tendência negativa pré-pandemia, acentuada a partir do ano de 2018, com uma redução de 23,6% na oferta. Durante a pandemia, a tendência negativa persistiu, evidenciada pela falta de significância estatística da variável que representa a mudança de tendência da série. O modelo escolhido que melhor se adequou à série foi SARIMA(2,1,1)(2,0,0)12, e estimou uma contração de 25,75% na quantidade de viagens no período de março de 2020 a dezembro de 2022.

Considerando a importância do distanciamento social na redução da disseminação da doença, a diminuição da oferta pode ter impactado a segurança dos usuários, evidenciando novamente a fragilidade do modelo de financiamento desse setor. A partir de maio de 2022, houve um aumento gradual na quantidade de viagens, alcançando, em dezembro, 76% do nível de oferta registrado em fevereiro de 2020.

Por outro lado, a frota de veículos individuais aumentou nos últimos anos, com os automóveis representando 70,84% e as motocicletas 11,89% da frota total do município em 2022. Observou-se uma contração significativa no tráfego em abril de 2020, seguida por uma recuperação gradual nos meses subsequentes. Tanto o fluxo de veículos como a demanda do transporte público por ônibus apresentaram flutuações no período pós-pandemia. Contudo, observou-se que a recuperação da demanda foi mais lenta, alcançando 59,6% do nível médio pré-pandêmico em dezembro de 2022, enquanto o fluxo de veículos atingiu 94,4% no mesmo mês. Portanto, a mudança no perfil de deslocamento pode ser atribuída não apenas às adaptações para reduzir o risco de contaminação, mas também à crescente preferência pelo transporte individual.

Adicionalmente, a adoção do trabalho remoto possivelmente contribuiu para a redução do uso do transporte coletivo e do fluxo de veículos. Entre maio e novembro de 2020, o percentual de pessoas trabalhando remotamente diminuiu de 37,0% em maio para 23,7% em novembro. A diminuição do percentual de pessoas trabalhando remotamente entre maio e novembro de 2020 coincidiu com um aumento gradual no fluxo de veículos, enquanto a demanda do transporte público registrou aumentos graduais, porém em proporções menores.

Ao analisar o rendimento médio mensal das pessoas em trabalho remoto, verificou-se que a maioria estava na faixa de 3 a 10 salários mínimos. A POF indicou que aqueles com salários entre 3 a 10 salários mínimos comprometem sua renda de maneira semelhante com o transporte urbano e individual. No entanto, aqueles com salários entre 6 a 10 salários mínimos comprometem mais a sua renda com o transporte individual. Isso sugere que muitos que deixaram de ir ao trabalho provavelmente deixaram de utilizar o transporte individual, e ao retornarem ao trabalho presencial, possivelmente retomaram o mesmo meio de transporte. Além disso, a continuidade da adoção do trabalho remoto pode ter influenciado para a manutenção de níveis de fluxo de veículos levemente abaixo dos registrados antes da pandemia.

Diante disso, e considerando a importância do transporte público para as atividades socioeconômicas e culturais, especialmente pelo papel fundamental que o transporte por ônibus desempenha no sistema de transporte do município do Rio de Janeiro, o apoio

financeiro se mostrou essencial para enfrentar os impactos decorrentes da pandemia. Entretanto, além desse subsídio, o investimento em infraestrutura e segurança, juntamente com o planejamento operacional do transporte público, são essenciais para melhorar as operações e garantir um serviço de qualidade, seguro e confiável, fomentando assim o uso do transporte coletivo em detrimento do individual.

Quanto às limitações do estudo, destaca-se a limitação temporal decorrente da indisponibilidade de dados públicos abrangendo períodos mais longos. A SMTR disponibiliza os dados sobre a operação de ônibus a partir de 2015, enquanto o IGVOL está disponível a partir de novembro do mesmo ano. Os dados relacionados ao teletrabalho apresentaram desafios adicionais, visto que a primeira pesquisa a incorporar perguntas sobre trabalho remoto foi a PNAD COVID-19, realizada somente entre maio e novembro de 2020, e reintroduzida na PNAD Contínua apenas em 2022. Cabe ressaltar que, na PNAD Contínua, as informações foram agregadas em unidades territoriais diferentes. A quantidade de pessoas em teletrabalho no domicílio foi apresentada por região metropolitana, enquanto o perfil socioeconômico e o tipo de ocupação daqueles que adotaram o teletrabalho foram divulgados em nível nacional, e o rendimento médio mensal foi disponibilizado por estado. Devido à natureza estatística experimental desses dados, ainda não existem informações com detalhamento por município. Ademais, existe uma lacuna nos dados referentes ao teletrabalho entre o último trimestre de 2020 e o último trimestre de 2022, o que limita a compreensão completa da adoção dessa modalidade durante esse intervalo de tempo. A Pesquisa de Orçamentos Familiares 2017-2018 também não possui resultados por município.

Outros elementos podem ter impactado a mobilidade urbana, como a desaceleração econômica, que resultou na diminuição de empregos, e o aumento das compras online. Além disso, a utilização de serviços de *ridesourcing* e a mobilidade ativa, incluindo o uso de bicicletas e caminhadas, também podem ter modificado os perfis de deslocamentos. Sugere-se para trabalhos futuros investigar esses fatores e sua possível relação com o uso do transporte público coletivo. Avaliar os impactos em outros modais de transporte público, como trens e metrô, também é sugerido. Além disso, propõe-se a extensão deste estudo para outras cidades ou regiões metropolitanas em trabalhos futuros.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDULLAH, M.; ALI, N.; HUSSAIN, S. A. *et al.* Measuring changes in travel behavior pattern due to COVID-19 in a developing country: A case study of Pakistan. **Transport Policy**, v. 108, p. 21-23, 2021. Disponível em: <<https://doi.org/10.1016/j.tranpol.2021.04.023>>. Acesso em: 05 nov. 2022.
- ANTUNES, J. L. F.; CARDOSO, M. R. A. Uso da análise de séries temporais em estudos epidemiológicos. **Epidemiologia e Serviços de Saúde**, v. 24, p. 565-576, 2015. Disponível em: <<https://www.scielo.br/j/ress/a/zzG7bfRbP7xSmqgWX7FfGZL/?lang=pt>>. Acesso em: 10 ago. 2023.
- ASSOCIAÇÃO NACIONAL DAS EMPRESAS DE TRANSPORTES URBANOS. **Anuário NTU: 2020-2021**. Associação Nacional das Empresas de Transportes Urbanos, Brasília: NTU, 2021. Disponível em: <<https://ntu.org.br/novo/upload/Publicacao/Pub637677328510412847.pdf>>. Acesso em: 30 nov. 2022.
- BAZANI, A. **Mais empresas de ônibus encerram atividades no Rio de Janeiro**. **Diário do Transporte**, 2018a. Disponível em: <<https://diariodotransporte.com.br/2018/05/22/mais-empresas-de-onibus-encerram-atividades-no-rio-de-janeiro/>>. Acesso em: 02 dez. 2023.
- BAZANI, A. **Justiça determina que tarifa de ônibus do Rio de Janeiro volte para R\$3,40**. **Diário do Transporte**, 2018b. Disponível em: <<https://diariodotransporte.com.br/2018/02/08/justica-determina-que-tarifa-de-onibus-do-rio-de-janeiro-volte-para-r-340/>>. Acesso em: 02 dez. 2023.
- BENAVIDES, F. G.; AMABLE, M.; CORNELIO, C. *et al.* El futuro del trabajo tras la COVID-19: el papel incierto del teletrabajo en el domicilio. **Revista Brasileira de Saúde Ocupacional**, v. 46, 2021. Disponível em: <<https://doi.org/10.1590/2317-6369000037820>>. Acesso em: 15 jun. 2023.
- BERNAL, J. L.; CUMMINS, S.; GASPARINI, A. Interrupted time series regression for the evaluation of public health interventions: a tutorial. **International journal of epidemiology**, v. 46, n. 1, p. 348-355, 2017. Disponível em: <<https://doi.org/10.1093/ije/dyw098>>. Acesso em: 7 mar. 2023.
- BORGATTO, A. F. **Análise de Intervenção em Séries Temporais: Aplicações em Transporte Urbano**. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, Lavras, 2000. Disponível em: <http://repositorio.ufla.br/jspui/bitstream/1/15569/1/DISSERTA%C3%A7%C3%A3O_An%C3%A1lise%20de%20interven%C3%A7%C3%A3o%20em%20s%C3%A3ries%20temporais%20aplica%C3%A7%C3%A7%C3%A3o%20em%20transporte%20urbano.pdf>. Acesso em: 3 out. 2023.
- CARNEIRO, C. M. O. *et al.* Avaliação dos efeitos da pandemia de COVID-19 na relação oferta/demandas do transporte público na cidade do recife. **Anais do Congresso de Pesquisa e**

Ensino em Transportes, Fortaleza, 2022. Disponível em: <<https://proceedings.science/anpet-2022/trabalhos/avaliacao-dos-efeitos-da-pandemia-de-covid-19-na-relacao-ofertademandado-transp?lang=pt-br>>. Acesso em: 15 jun. 2023.

CAVALCANTE, J. R.; ABREU, A. J. L. COVID-19 no município do Rio de Janeiro: uma análise espacial da ocorrência dos primeiros casos e óbitos confirmados. **Epidemiologia e Serviços de Saúde**, v. 29, p.e2020204, 2020. Disponível em: <<https://doi.org/10.5123/S1679-49742020000300007>>. Acesso em: Acesso em: 9 jan. 2023.

CONSELHO NACIONAL DE SAÚDE. RECOMENDAÇÃO Nº 036, DE 11 DE MAIO DE 2020. Disponível em <http://conselho.saude.gov.br/recomendacoes-cns/1163-recomendac-a-o-n-036-de-11-de-maio-de-2020>. Acesso em: 10 fev. 2023.

COSTA, C.S.; PITOMBO, C.S.; SOUZA, F.L.U. 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, 4573, Abr. 2022. Disponível em: <<https://doi.org/10.3390/su14084573>>. Acesso em: 23 out. 2022.

DATA.RIO. **Movimento médio diário de passageiros, segundo os transportes rodoviário, ferroviário, hidroviário e aeroviário no Município do Rio de Janeiro entre 1995-2022**. Prefeitura da cidade do Rio de Janeiro, 2023a. Disponível em: <<https://www.data.rio/documents/f338ce534dd5427cbd9fc780ef63f4cd>>. Acesso em: 19 out. 2023.

DATA.RIO. **Total de linhas, frota operante, passageiros transportados, viagens realizadas, quilometragem coberta, combustível utilizado e pessoal ocupado pelo sistema de ônibus no Município do Rio de Janeiro entre 1984-2022**. Prefeitura da cidade do Rio de Janeiro, 2023b. Disponível em: <<https://www.data.rio/documents/c09ef8f7d5de472c8624639070d97868/about>>. Acesso em: 03 nov. 2023.

DATA.RIO. **Painel Rio COVID-19**. Prefeitura da Cidade do Rio de Janeiro, 2023C. Disponível em:<<https://www.data.rio/apps/PCRJ::painel-rio-covid-19/about>>. Acesso em: 13 dez. 2023.

ENDERS, W. **Applied Econometric Time Series**, 4 ed. Hoboken: Wiley, Cop, 2014.

FREITAS, C. M.; Barcellos, C.; Villela, D. A. M. et al. **Boletim Observatório Covid-19 - Boletim especial: balanço de dois anos da pandemia Covid-19 - janeiro de 2020 a janeiro de 2022**. Observatório Covid-19, Fiocruz, 2022. Disponível em: <<https://www.arca.fiocruz.br/handle/icict/55828>>. Acesso em: 30 nov 2023.

FREITAS, R. R.; SAGAWE, T. R.; MOURA, A. C. D. et al. **COVID-19 e o Teletrabalho: pesquisa de percepção antes e durante a pandemia na região metropolitana do Rio de Janeiro**. CEFET-RJ Campus Itaguaí, 2020. Disponível em: <<https://doi.org/10.5281/zenodo.3942295>>. Acesso em: 15 jun. 2023.

FULLER, D. *et al.* The impact of public transportation strikes on use of a bicycle share program in London: Interrupted time series design. **Preventive medicine**, v. 54, n. 1, p. 74-76, 2012. Disponível em: <<https://doi.org/10.1016/j.ypmed.2011.09.021>>. Acesso em: 12 mar. 2023.

GÓES, G. S.; MARTINS, F. S.; NASCIMENTO, J. A. S. O trabalho remoto e a pandemia: o que a pnad covid- 19 nos mostrou. **Carta Conjuntura (Instituto de Pesquisa Econômica Aplicada)**, p. 1-16, 2021. Disponível em: <<https://www.ipea.gov.br/cartadeconjuntura/index.php/2021/02/o-trabalho-remoto-e-a-pandemia-o-que-a-pnad-covid-19-nos-mostrou/>>. Acesso em: 01 nov. 2022.

LINDEN, A.; ADAMS, J. L.; ROBERTS, N. Evaluating disease management program effectiveness: an introduction to time-series analysis. **Disease Management**, v. 6, n. 4, p. 243-255, 2003. Disponível em: <<https://doi.org/10.1089/109350703322682559>>. Acesso em: 19 out. 2023.

LOPES, S. P. Elaboração de modelos matemáticos para análise, avaliação e previsão do comportamento da motorização no Brasil. Tese (Doutorado em Engenharia de Transportes), COPPE, Universidade do Rio de Janeiro, 2005. Disponível em: <<http://www.redpgv.coppe.ufrj.br/index.php/pt-BR/producao-da-rede/dissertacoes-e-teses/2005/84-sergio-pedro-lopes-coppe2005/file>>. Acesso em: 16 dez. 2023.

IBGE. **Município do Rio de Janeiro - Panorama**. 2023. Disponível em: <<https://cidades.ibge.gov.br/brasil/rj/rio-de-janeiro/panorama>>. Acesso em: 19 out. 2023.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**, 2 ed. OTexts: Melbourne, Australia, 2018.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. **Journal of statistical software**, v. 27, p. 1-22, 2008. Disponível em <<https://doi.org/10.18637/jss.v027.i03>>. Acesso em: 19 out. 2023.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting methods and applications**. 3 ed. New York: John Wiley & Sons, 1998.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. Hoboken, New Jersey: John Wiley & Sons, Inc., 2008.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**, 2 ed. Editora Blucher, 2006.

NTU. População quer tarifa mais barata e transporte de qualidade. **Revista NTU Urbano**, ano v, número 29, set./out. 2017. Disponível em: <<https://ntu.org.br/novo/upload/Publicacao/Pub636462520486071584.pdf>>. Acesso em: 24 nov. 2023.

PEREIRA, G. P.; GRANDO, K. D.; MACHADO, M. **Análise de regressão linear com o auxílio do RStudio**. Passo Fundo, 2021. Disponível em:

<https://www.upf.br/_uploads/Conteudo/cepeac/textos-discussao/texto-07-2021.pdf>. Acesso em: 20 out. 2023.

PEREIRA, T. P.; ALBUQUERQUE, C. S.; MATTOS, V. L. D. *et al.* 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. **Anais do Encontro Nacional de Modelagem Computacional e Encontro de Ciência e Tecnologia de Materiais**, 2021. Disponível em: <<http://dx.doi.org/10.29327/154013.24-22>>. Acesso em: 19 out. 2023.

PEREIRA, R. H. M.; WARMAR, L.; PARGA, J. *et al.* Tendências e desigualdades da mobilidade urbana no Brasil I: o uso do transporte coletivo e individual. **Instituto de Pesquisa Econômica Aplicada**. Rio de Janeiro: IPEA, 2021. Disponível em <<http://repositorio.ipea.gov.br/handle/11058/10713>>. Acesso em: 15 nov. 2023.

PÉREZ, F. L. **Análise de Séries Temporais**. Departamento de Estatística. Universidade Federal do Paraná, 2022. Disponível em: <<http://leg.ufpr.br/~lucambio/STemporais/STemporais.html>>. Acesso em: 4 jan. 2023.

RAMIS, J. E.; SANTOS, E. A. Uso de automóveis e o caos urbano: considerações sobre o planejamento de transportes das grandes cidades. **Journal of Transport Literature**, v. 6, p. 164-177, 2012. Disponível em: <<https://www.scielo.br/j/jtl/a/JfQLJ84ZrzDzTbL634rHg6g/?format=pdf&lang=pt>>. Acesso em: 18 nov. 2023.

REIS, M. M. Estatística aplicada à administração. Florianópolis : Departamento de Ciências da Administração/UFSC, 2008. Disponível em: <https://cesad.ufs.br/ORBI/public/uploadCatalogo/14575016022012Estatistica_APLICADA_a_Administracao_Aula_1.pdf>. Acesso em: 13. jan. 2024.

RIO ÔNIBUS. **Números do sistema**. 2024a. Disponível em: <<https://rioonibus.com/numeros-do-sistema/>>. Acesso em: 16 jan. 2024.

RIO ÔNIBUS. **Consórcios e empresas**. 2024b. Disponível em: <<https://rioonibus.com/>>. Acesso em: 16 jan. 2024.

RODRIGUES, F. S. **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)**. Tese (Doutorado em Doenças Tropicais) - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2022.

SCHAFFER, A. L.; DOBBINS, T. A.; PEARSON, S.. Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. **BMC medical research methodology**, v. 21, n. 1, p. 1-12, 2021. Disponível em: <<https://bmcmedresmethodol.biomedcentral.com/articles/10.1186/s12874-021-01235-8>>. Acesso em: 23 mai. 2023.

SHAKIBAEI, S.; JONG, G.C.; ALPKÖKIN, P.; H. RASHIDI, T.H. Impact of the COVID-19 pandemic on travel behavior in Istanbul: A panel data analysis. **Sustainable Cities and Society**, 65, 102619, Nov. 2020. Disponível em: <<https://doi.org/10.1016/j.scs.2020.102619>>. Acesso em: 23 out. 2022.

SILVA, E. R.; CARDOSO, B. C.; SANTOS, M. P. S. O aumento da taxa de motorização de motocicletas no Brasil. **Revista Brasileira de Administração Científica**, v. 2, n. 2, p. 49-63, 2011. Disponível em: <<http://dx.doi.org/10.6008/ESS2179-684X.2011.002.0004>>. Acesso em: 20 nov. 2023.

SILVA, R.; PITOMBO, C.S.; PEDREIRA JÚNIOR, J.U. *et al.* Changes in Mobility and Challenges to the Transport Sector in Brazil due to COVID-19. In: ZHANG, J; HAYASHI, Y. **Transportation Amid Pandemics: Lessons Learned from COVID-19**. Elsevier: Amsterdam, The Netherlands, 2022.

SILVEIRA, A. G.; MATTOS, V. L. D.; NAKAMURA, L. R. *et al.* Análise do Valor-p Determinado pela Estatística τ na Aplicação do Teste de Dickey-Fuller Aumentado. **Trends in Computational and Applied Mathematics**, v. 23, p. 283-298, 2022. Disponível em: <<https://doi.org/10.5540/tcam.2022.023.02.00283>>. Acesso em: 19 out. 2023.

SMTR. **Descritivo do sistema de transporte público coletivo.** Prefeitura da cidade do Rio de Janeiro, Secretaria Municipal de Transportes, 2022. Disponível em:<<http://transportes.prefeitura.rio/wp-content/uploads/sites/31/2022/02/SMTR-Licitac%CC%A7a%CC%83o-Bilhetagem-ANEXO-I.5-Descritivo-do-Sistema-de-Transporte-Pu%CC%81blico-Coletivo.pdf>>. Acesso em: 18 jan.2024.

SMTR. **Edital e anexos.** Prefeitura da cidade do Rio de Janeiro, Secretaria Municipal de Transportes, 2023a. Disponível em: <[https://transportes.prefeitura.rio/wp-content/uploads/sites/31/2023/05/SMTR-BRT-Operacao-EDITAL-E-ANEXOS-v22-2023-05-15.pdf](http://transportes.prefeitura.rio/wp-content/uploads/sites/31/2023/05/SMTR-BRT-Operacao-EDITAL-E-ANEXOS-v22-2023-05-15.pdf)>. Acesso em: 18 jan.2024.

SMTR. **Subsídio.** Prefeitura da cidade do Rio de Janeiro. 2023b. Disponível em: <[https://transportes.prefeitura.rio/subsidio/](http://transportes.prefeitura.rio/subsidio/)>. Acesso em: 14 jun. 2023.

SMTR. **Painel subsídios serviço público de passageiros por ônibus.** Prefeitura da cidade do Rio de Janeiro. 2023c. Disponível em: <https://bit.ly/painel_subsidios_sppo>. Acesso em: 14 jun. 2023.

SOBRAL, M. T. M. C.; ROCHA, L. M. Teste de Durbin Watson: aplicação para variável data do evento. **Anais do Congresso Brasileiro de Engenharia de Avaliações e Perícias**, 2019. Disponível em: <<https://ibape-nacional.com.br/biblioteca/wp-content/uploads/2020/02/PE-26-Teste-de-Durbin-Watson.pdf>>. Acesso em: 21 out. 2023.

STUMPF, G. **O ciclo vicioso dos congestionamentos e a qualidade do transporte público.** Linkedin, 2018. Disponível em: <<https://www.linkedin.com/pulse/o-ciclo-vicioso-dos-congestionamentos-e-qualidade-do-transporte-publico-stumpf/?originalSubdomain=pt>>. Acesso em: 20 dez. 2023.

TURNER, S.L., KARAHALIOS, A., FORBES, A.B. *et al.* Comparison of six statistical methods for interrupted time series studies: empirical evaluation of 190 published series. **BMC Medical Research Methodology**, v. 21, n. 1, p. 1-19, 2021. Disponível em: <<https://doi.org/10.1186/s12874-021-01306-w>>. Acesso em: 20 out. 2023.

VOS, J. The effect of COVID-19 and subsequent social distancing on travel behavior. **Transportation Research Interdisciplinary Perspectives**, v. 5, p. 100121, 2020. Disponível em: <<https://doi.org/10.1016/j.trip.2020.100121>>. Acesso em: 5 nov. 2022.

WAGNER, A. K.; SOUMERAI, S. B.; ZHANG, F. *et al.* Segmented regression analysis of interrupted time series studies in medication use research. **Journal of clinical pharmacy and therapeutics**, v. 27, n. 4, p. 299-309, 2002. Disponível em: <<https://doi.org/10.1046/j.1365-2710.2002.00430.x>>. Acesso em: 7 mar. 2023.

YANG, Y.; CAO, M.; CHENG, L.; ZHAI, K.; ZHAO, X.; VOS, J. Exploring the relationship between the COVID-19 pandemic and changes in travel behaviour: A qualitative study. **Transportation Research Interdisciplinary Perspectives**, 11, 100450, Ago. 2021. Disponível em: <<https://doi.org/10.1016/j.trip.2021.100450>>. Acesso em: 5 nov. 2022.

APÊNDICE A - VALORES OBSERVADOS, VALORES PREVISTOS DO CENÁRIO CONTRAFACTUAL, DIFERENÇA E VARIAÇÃO PERCENTUAL DO NÚMERO DE PASSAGEIROS TRANSPORTADOS ENTRE MARÇO DE 2020 A DEZEMBRO DE 2022.

Mês/Ano	Valor observado	Valor previsto	Diferença	Variação %
	(A)	(B)	(A) - (B)	(A) - (B)/(B)
março/2020	56,84	77,64	-20,80	-26,79
abril/2020	24,05	76,11	-52,06	-68,40
maio/2020	25,60	79,74	-54,14	-67,89
junho/2020	31,28	75,06	-43,78	-58,33
julho/2020	40,28	76,46	-36,17	-47,31
agosto/2020	43,49	81,52	-38,03	-46,65
setembro/2020	43,05	77,27	-32,21	-41,69
outubro/2020	47,84	81,24	-33,40	-41,12
novembro/2020	47,14	74,15	-27,01	-36,42
dezembro/2020	47,93	72,65	-24,72	-34,02
janeiro/2021	45,65	68,33	-22,67	-33,18
fevereiro/2021	42,81	65,60	-22,79	-34,74
março/2021	47,15	70,04	-22,89	-32,68
abril/2021	42,56	69,91	-27,35	-39,13
maio/2021	46,73	73,82	-27,09	-36,70
junho/2021	48,29	68,90	-20,61	-29,91
julho/2021	51,79	70,67	-18,88	-26,72
agosto/2021	53,16	74,49	-21,33	-28,63
setembro/2021	52,75	71,37	-18,62	-26,09
outubro/2021	54,94	74,83	-19,88	-26,57
novembro/2021	55,73	68,30	-12,57	-18,41
dezembro/2021	56,68	66,77	-10,09	-15,11
janeiro/2022	47,53	62,70	-15,17	-24,20
fevereiro/2022	50,32	59,84	-9,52	-15,90
março/2022	56,77	64,90	-8,14	-12,54
abril/2022	52,91	64,34	-11,43	-17,77

maio/2022	60,40	67,59	-7,18	-10,63
junho/2022	56,87	63,47	-6,60	-10,39
julho/2022	56,65	64,85	-8,20	-12,65
agosto/2022	61,80	68,52	-6,72	-9,80
setembro/2022	59,40	65,49	-6,10	-9,31
outubro/2022	58,96	68,61	-9,65	-14,07
novembro/2022	58,11	62,85	-4,75	-7,55
dezembro/2022	57,80	61,55	-3,75	-6,09

APÊNDICE B - VALORES OBSERVADOS, VALORES PREVISTOS DO CENÁRIO CONTRAFACTUAL, DIFERENÇA E VARIAÇÃO PERCENTUAL DA QUANTIDADE DE VIAGENS REALIZADAS ENTRE MARÇO DE 2020 A DEZEMBRO DE 2022.

Mês/Ano	Valor observado	Valor previsto	Diferença	Variação %
	(A)	(B)	(A) - (B)	(A) - (B)/(B)
março/2020	798,00	933,77	135,77	-14,54
abril/2020	445,78	873,48	427,70	-48,97
maio/2020	465,83	903,88	-438,05	-48,46
junho/2020	521,42	870,86	-349,44	-40,13
julho/2020	624,77	934,22	309,45	-33,12
agosto/2020	659,71	916,26	256,55	-28,00
setembro/2020	655,76	864,66	208,89	-24,16
outubro/2020	671,58	900,67	229,09	-25,44
novembro/2020	643,03	848,78	205,75	-24,24
dezembro/2020	666,00	861,70	195,70	-22,71
janeiro/2021	645,06	867,59	-222,54	-25,65
fevereiro/2021	591,01	787,91	-196,90	-24,99
março/2021	643,74	822,08	-178,34	-21,69
abril/2021	577,46	801,26	-223,80	-27,93
maio/2021	594,41	833,02	-238,61	-28,64
junho/2021	579,98	800,24	-220,27	-27,53
julho/2021	610,37	841,90	-231,54	-27,50
agosto/2021	603,70	829,67	-225,97	-27,24
setembro/2021	587,53	793,27	-205,74	-25,94
outubro/2021	601,72	816,72	-215,00	-26,33
novembro/2021	569,25	772,19	-202,95	-26,28
dezembro/2021	571,41	784,72	-213,32	-27,18
janeiro/2022	546,06	785,49	-239,42	-30,48
fevereiro/2022	529,38	717,96	-188,58	-26,27
março/2022	571,28	751,27	-180,00	-23,96
abril/2022	524,12	724,04	-199,91	-27,61

maio/2022	577,63	744,31	-166,68	-22,39
junho/2022	570,96	722,82	-151,87	-21,01
julho/2022	607,56	757,52	-149,96	-19,80
agosto/2022	630,58	747,56	-116,98	-15,65
setembro/2022	622,43	718,53	-96,10	-13,37
outubro/2022	634,84	738,19	-103,34	-14,00
novembro/2022	609,89	706,57	-96,67	-13,68
dezembro/2022	657,59	714,88	-57,30	-8,01
