

## **EFEITOS DA PANDEMIA DE COVID-19 NO TRANSPORTE INTERMUNICIPAL DE PASSAGEIROS DO RIO GRANDE DO SUL: Uma proposta de Metodologia empírica**

Luiz Henrique Gaston<sup>9</sup>

**Resumo:** O transporte público no Brasil, em especial o modal rodoviário, apresenta quadro sistêmico de crise e dificuldades com piora na qualidade dos serviços e majoração constante das tarifas. Mesmo antes da pandemia, a situação já apontava para um quadro crítico. A pandemia de Covid-19 pode ter agravado ainda mais o desequilíbrio econômico-financeiro, trazendo novos desafios ao cenário já conturbado. O presente estudo objetiva desenvolver metodologia para se avaliar os impactos do vírus sobre a demanda e a receita dos dois principais sistemas de transporte intermunicipal de passageiros do Rio Grande do Sul, o da Região Metropolitana de Porto Alegre e o de Longo Curso. Foram utilizados métodos econométricos de análise de séries temporais, a metodologia Box-Jenkins adaptada, quantificando os efeitos nas variáveis analisadas.

**Palavras-chave:** Transporte Intermunicipal de Passageiros. Covid-19. Impactos. Box-Jenkins. Séries Temporais.

### **Effects of the Covid-19 Pandemic on Intermunicipal Passenger Transport in Rio Grande do Sul: an Empirical Methodology Proposal**

**Abstract:** Public transport in Brazil, especially road transport, presents a systemic picture of crisis and difficulties with worsening in the quality of services and constant increase in tariffs. Even before the pandemic, the situation was already pointing to a critical situation. The Covid-19 pandemic may have further aggravated the economic and financial imbalance, bringing new challenges to the already troubled scenario. The present study aims to develop a methodology to assess the impacts of the virus on the demand and revenue of the two main intercity passenger transport systems in Rio Grande do Sul, the Metropolitan Region of Porto Alegre and the Long Haul. Econometric methods of time series analysis were used, the adapted Box-Jenkins methodology, quantifying the effects on the analyzed variables.

**Keywords:** Intermunicipal Passenger Transport. Covid-19.Effects.Box-Jenkins.Time Series.

---

<sup>9</sup> Mestre em Economia Aplicada PPGE/UFRGS. Especialista em Contabilidade, Auditoria e Finanças Governamentais. UFRGS/DCCA/NECON. Bacharel em Ciências Econômicas/UFRGS. Graduando em Ciências Jurídicas e Sociais/UFRGS. Técnico Superior Economista da Agência Estadual de Regulação dos Serviços Públicos do RS-AGERGS.

## Introdução

O sistema de transportes intermunicipal do Estado do Rio Grande do Sul constitui importante tema na análise procedida pelos órgãos de Estado. De maneira bastante reduzida, podemos caracterizá-lo como dividido em aglomerações urbanas e um sistema de longo curso, transportando usuários entre as aglomerações. Estas se dividindo em quatro: Região Metropolitana de Porto Alegre (RMPA), atendendo as cidades que orbitam a capital; Região Metropolitana da Serra Gaúcha (RMSG); Aglomeração Urbana do Litoral Norte; e Aglomeração Urbana da Região Sul, possuindo Pelotas como centro.

Quanto à atuação de órgãos de Estado, existe duplo papel entre aqueles que concedem o serviço à iniciativa privada e aquele que empreende a regulação deles. Nesse sentido, a Fundação Estadual de Planejamento Metropolitano e Regional (METROPLAN) exerce a função de fiscalização no âmbito micro, enquanto poder concedente, do serviço das aglomerações. Já o Departamento Autônomo de Estradas e Rodagem (DAER) é seu congêneres no sistema de longo curso. Ambos atuam na fiscalização do serviço quanto a horários, regularidade e reclamações pontuais de usuários. A regulação é exercida pela Agência Estadual de Regulação dos Serviços Públicos Delegados (AGERGS), que objetiva a modicidade tarifária e a qualidade dos serviços delegados. Em outras palavras, definem-se tarifas e qualidade de maneira macro, para os dois sistemas citados.

Nesse contexto, mesmo antes da pandemia de Covid-19, já se ressaltava a crise sistêmica enfrentada pelos transportes no Estado do Rio Grande do Sul. Sucessivas quedas no número de usuários e pressões sobre as tarifas e qualidade acabavam por apontar um dos maiores desafios à atividade de regulação. A pergunta que se fazia era: Como reverter o quadro garantindo a qualidade em um ambiente de crise com redução significativa na rentabilidade das empresas e no equilíbrio econômico dos serviços, mantendo a modicidade tarifária?

A epidemia de coronavírus, em 2020, encontrou esse cenário de dificuldades, agravando-o de maneira significativa. No momento em que se escreve este trabalho, o Brasil ultrapassou as cento e oitenta mil vidas perdidas, acontecendo uma segunda onda de contágios e aceleração no número de casos. Os efeitos sobre a atividade econômica foram inegáveis, gerando queda no produto e na renda tanto locais quanto nacionais. Nesse sentido, o transporte intermunicipal de passageiros experimentou diminuição brusca e abrupta na demanda e na receita dos serviços.

Este trabalho, portanto, objetiva apresentar uma metodologia para se avaliar e quantificar os possíveis efeitos da pandemia sobre os sistemas. Aqui se faz necessária uma primeira advertência. De maneira nenhuma se afirma que todo o efeito quantificado deva ser atribuído à pandemia, ou seja, relação de causa e efeito perfeita. Busca-se, entretanto, através de modelos, verificar, dada a tendência de queda nas variáveis e a crise sistêmica, para o ano de 2020, quanto maior foi a queda do que seria esperado? Segundo, utilizou-se apenas dois

sistemas, os quais representam mais de noventa por cento, tanto da receita quanto no número de passageiros, o da Região Metropolitana de Porto Alegre e o do Sistema de Longo Curso. Podendo o trabalho, em um segundo momento, ser expandido para os demais sistemas. Isso se originou na disponibilidade de dados, a RMPA possui bilhetagem eletrônica com maior facilidade de acesso aos mesmos, já o Longo Curso dispõe de banco de dados acessível.

Os métodos utilizados serão econométricos, com o uso de análise de séries temporais, estrutura que parece adequada ao problema proposto. O ponto de partida será a consagrada metodologia Box-Jenkins para análise de séries temporais, modificando-a e adaptando-a ao contexto. Dividir-se-á o trabalho, além desta introdução, em uma breve revisão teórica, apresentando a situação dos sistemas de Longo Curso e da Região Metropolitana de Porto Alegre e os conceitos básicos utilizados, metodologia, onde se versará sobre o método utilizado, resultados e conclusão, com a síntese dos achados. Sempre buscando atingir o objetivo principal de o trabalho apresentar breve contribuição a uma possível consolidação de metodologia para se quantificar e analisar os efeitos da pandemia de Covid-19.

## **Revisão Teórica**

### **Caracterização dos sistemas pré-pandemia de Covid-19**


Deve-se começar o trabalho caracterizando os dois sistemas que serão estudados. Como dito na introdução, ainda que não caracterizem a totalidade do sistema de transportes intermunicipal de passageiros no Rio Grande do Sul (TIP), o sistema de Longo Curso e a Região Metropolitana de Porto Alegre, juntos, em termos de usuários e receita, possuem mais de noventa por cento do que é verificado em todo o TIP.

O TIP Longo Curso é um sistema gerenciado pelo DAER, que interliga o Rio Grande do Sul de ponta a ponta. Quando se pensa em termos de formação do sistema de transportes, este é o mais antigo, dando origem aos demais, os quais foram segregados, passando à gestão da METROPLAN. Em termos de organização, cabe destacar, que não é necessariamente a questão de distância que caracteriza uma linha como sendo de longo curso. Na verdade, o fato de transportar passageiros entre as Aglomerações assim a define. Ou seja, por exemplo, o transporte entre um município da Região Metropolitana da Serra Gaúcha e outro da Região de Porto Alegre, dessa forma, é definido como de longo curso. Assim como entre as regiões não organizadas em aglomerações e as mesmas.

Já quando se fala em mercado econômico, o Longo Curso se caracteriza pela alta concentração, mesmo que com grande número de empresas pouco representativas para o sistema. De um total de aproximado de 200 empresas, apenas treze abarcam cerca de oitenta

por cento da receita e do número de passageiros. Segundo os boletins de Oferta e Demanda (BOD) compilados pelo DAER para o ano de 2019, encontramos o expressivo número de 30.736.351 de passageiros transportados. Já em escala de receita, R\$ 1.367.977.736,00 em valores constantes em dezembro daquele ano. Trata-se, portanto, de sistema que, anualmente, transporta cerca de 31 milhões de passageiros, com receita bilionária. Mensalmente, entre janeiro de 2015 e dezembro de 2019, pode-se verificar a evolução dele, em termos de passageiros.

Gráfico 1 – Evolução no número de Passageiros Mensais Transportados no Longo Curso entre Janeiro de 2015 e Dezembro de 2020



Fonte: Elaboração própria com dados do Boletim de Oferta e Demanda do DAER/RS


Do gráfico acima, uma primeira constatação em relação ao sistema de Longo Curso pode ser realizada. Uma vez que a linha azul representa a evolução numérica nos passageiros transportados mês a mês, entre janeiro de 2015 e dezembro de 2019, e a linha vermelha, a tendência central da série suavizada, podemos verificar a queda na demanda no período analisado. Mesmo antes da pandemia, já se observava significativa saída de usuários do sistema. Acelerando-se a partir de 2019.

Interessante notar que essa tendência poderia estar prejudicando sobremaneira o equilíbrio econômico-financeiro do sistema de Longo Curso. Entretanto, para o mesmo período, em valores constantes de dezembro de 2019, a análise da Receita do Total do Sistema de Longo Curso aponta caminho diverso do verificado. Em 2017, a Agência Estadual de Regulação dos Serviços Público do Rio Grande do Sul efetuou a revisão dos parâmetros de

custos e receitas reajustando o valor do coeficiente tarifário, ou seja, da remuneração por quilômetro rodado dos serviços.

Do gráfico abaixo, pode-se perceber que a revisão, a partir de 2018, reverteu, mesmo com queda no número de passageiros, a tendência de diminuição da receita, via saída de usuários. Há que se ressaltar, entretanto, que essa mesma política, frente a um cenário de esgotamento da capacidade de pagamento dos usuários, pode estar contribuindo para o agravamento da crise já vivenciada pelo sistema. Em resumo, a caracterização do Transporte Intermunicipal de Longo Curso no Estado do Rio Grande do Sul, pré-pandemia de Covid-19, era de um sistema com diminuição intensa no número de passageiros, tendência de queda na demanda, com manutenção do equilíbrio econômico-financeiro via política tarifária de majoração.

Gráfico2 – Evolução da Receita Mensal no Longo Curso entre Janeiro de 2015 e Dezembro de 2020 em valores constantes em R\$




Fonte: Elaboração própria com dados do Boletim de Oferta e Demanda do DAER/RS

Já a Região Metropolitana de Porto Alegre, enquanto ente organizativo para o planejamento Metropolitano, foi criada em 1973, concentrando cerca de 23% da população total do Estado do Rio Grande do Sul, sendo constituída por 14 municípios. Hoje em dia, tendo Porto Alegre como centro, 36 municípios compõem a Região, a partir de 2015, representando, conforme o censo de 2010, 37,7% da população do Estado (METROPLAN,2014).

Quando se consideram dados de demanda, a região, conforme sistema de bilhetagem eletrônica mantido pela Associação dos Transportadores Municipais (ATM), em 2019, transportou 78.329.998 passageiros. Quando se fala em receita do sistema, o *Business Intelligence* (BI) da AGERGS, com o uso dos Boletins de Oferta e Demanda, aponta para uma receita total de R\$ 550.176.857,32 no mesmo período.

Gráfico3 – Evolução no número de Passageiros Mensais Transportados na Região Metropolitana de Porto Alegre entre Janeiro de 2015 e Dezembro de 2019.



Fonte: Elaboração própria com dados da Bilhetagem Eletrônica operacional ATM.

Procedendo análise preliminar semelhante, para a RMPA, verifica-se tendência semelhante. A linha azul mostra a evolução numérica de passageiros transportados, passando de um pico acima de 10 milhões mensais para valores abaixo de 7. A linha vermelha, a tendência suavizada da série, aponta queda constante quase linear no número de passageiros entre janeiro de 2015 e dezembro de 2019. Ainda que não se possa, como feito na advertência acima, caracterizar o mesmo período para receita, a política tarifária de reajustes e revisões, com majoração de tarifas, tem sido semelhante.

## Metodologia e procedimentos econométricos

Como citado na introdução, o presente trabalho visa contribuir para o desenvolvimento de uma metodologia para se avaliar os efeitos da pandemia de Covid-19 no transporte intermunicipal do Estado do Rio Grande do Sul. Em outras palavras, visa-se subsidiar a tomada de decisão na política pública de transportes.

Cabe começar definindo política pública como aqui entendido. Política Pública é uma diretriz elaborada para enfrentar um problema público. Detalhando-se ainda a definição como sendo uma orientação à atividade ou à passividade de alguém. Ressaltando que, enquanto poder público, a decisão pode ser por agir ou não, frente ao problema enfrentado. Possuindo dois elementos fundamentais: a intencionalidade e a resposta a um problema público. De outra maneira, o tratamento a um problema entendido como coletivamente relevante (SECCHI, 2014).

Portanto, o problema que se coloca ao desenvolvimento e aplicação de uma metodologia, no presente caso, pode ser resumido: Frente a um sistema já em dificuldades, como quantificar e avaliar os efeitos da pandemia? Separá-los da tendência verificada de queda, também, mostra-se relevante ao estudo e às propostas de ação. Verificam-se mesmo fatores exógenos ao sistema e diferenciados da situação em 2020, como concorrência e substitutibilidade frente aos aplicativos de transportes, incentivos à aquisição de veículos individuais e mesmo à política tarifária.

Os dados disponíveis são séries temporais. Do ponto de vista econométrico, torna-se importante diferenciar a estrutura de dados que se apresenta para, corretamente, proceder à análise. Série temporal, portanto, é um conjunto de dados que consiste em observações sobre uma variável ou muitas variáveis ao longo do tempo. Diferente do corte transversal, a ordenação cronológica das observações em uma série temporal transmite informações potencialmente importantes (WOOLDRIDGE, 2018).

Uma metodologia bastante conhecida para se trabalhar séries temporais univariadas é a modelagem de Box, Jenkins e Reinsel (1994), como apresentada em Bueno (2012), consiste em:

1. Identificar as ordens  $p$  e  $q$  do modelo.
2. Estimar o modelo.
3. Verificar se os resíduos estimados não rejeitam a hipótese nula de que sejam um ruído branco. Se não rejeitam, passa-se ao próximo passo. Se rejeitam, retorna-se ao primeiro passo.
4. Prever.

Trata-se, portanto, de modelo de organização para se trabalhar as séries temporais e gerar previsões econometricamente desejáveis. Almeja-se gerar, com uma série univariada, uma previsão. Esta, a partir das informações contidas nos dados, demonstraria um cenário

possível para o que poderia ter sido o ano de 2020, sem pandemia de Covid-19, com as tendências verificadas anteriormente. De novo, não se está a afirmar nem uma relação de causa e efeito, nem mesmo que se deva agir frente às conclusões e aos achados. Apenas que eles podem servir de subsídio às decisões tomadas.

Outro fato notório que deve ser ressaltado é a crônica falta de dados ou mesmo a desorganização destes frente à necessidade de análises. Sempre se deve preferir dados confiáveis e somente realizar a análise quando disponíveis. Banco de dados com entradas manuais, em geral, acaba por levar a erros que impossibilitam o tratamento estatístico adequado. Mesmo o Estado do Rio Grande do Sul ainda carece de séries longas e confiáveis, não sendo recomendável, pela informação da série ser muito curta, análises inferiores a 5 anos anteriores, ou algo próximo a sessenta observações.

Partindo das advertências realizadas, buscou-se modificar a metodologia Box-Jenkins para o seguinte roteiro:

1. Definição da disponibilidade de dados e das variáveis de interesse.
2. Análise preliminar da informação contida na série através da decomposição dos componentes da série temporal.
3. Seleção dos modelos a serem aplicados e estimados.
4. Identificação dos parâmetros dos modelos respeitando as especificidades econométricas, principalmente quanto a resíduos.
5. A partir do modelo selecionado, gerar uma previsão para 2020.
6. Comparação dos modelos via critério de menores erros.
7. Comparação da previsão com os resultados dos dados de 2020.

Do roteiro acima, cabe empreender alguns detalhamentos preliminares. O primeiro deles diz respeito à seleção dos modelos a serem aplicados. Séries multivariadas, isto é, incluindo-se variáveis extras à análise, são justificáveis e, em certo sentido, desejáveis. Há que se ressaltar, entretanto, que a simplicidade, às vezes, pode levar ao melhor caminho. Para trabalhos futuros, pretende-se refinar o modelo nessa direção. Outro fator sobre o item é que dois tipos de modelos, mesmo na literatura, acabam por serem tradicionais nesse tipo de análise: 1. Modelos autorregressivos de média móvel (ARMA), com sua variante modelando sazonalidade (SARIMA); e 2. Modelos de Suavização Exponencial.

Conforme proposto, desejaremos observar o comportamento das variáveis de interesse para o Transporte Público Intermunicipal do Estado do Rio Grande do Sul no período de janeiro de 2015 a dezembro de 2019, gerando uma previsão para 2020. Quando se fala em modelos ARMA, tem-se as vantagens de que os mesmos são amplamente utilizados em estudos semelhantes e de não derivarem de nenhuma teoria econômica específica, possuindo o comportamento das variáveis só explicado pelos seus valores defasados e pelos erros. Sendo o modelo geral representado por:

$$Y_t = \mu + \theta_1 Z_{t-1} + \dots + \theta_p Z_{t-p} + u_t + \phi_1 u_{t-1} + \dots + \phi_q u_{t-q} \quad (1)$$



Onde  $Y_t = \text{variável explicada de interesse}$

$\mu = \text{intercepto};$

$\theta_p = \text{parâmetro autorregressivo de ordem } p;$

$\phi_q = \text{parâmetro autorregressivo de ordem } q;$

$u_t = \text{resíduo.}$

Segundo a metodologia Box-Jenkins, para modelar o processo ARIMA, primeiro identificamos a estacionariedade da série através dos testes de raiz unitária de Dickey-Fuller Aumentado (ADF) ou de Philip-Perron (PP). Caso se encontre raiz unitária, o processo será diferenciado até a estacionariedade (ENDERS, 1995 e HAMILTON, 1994).

A segunda etapa seria a identificação da ordem  $p$  e  $q$  do processo através da análise do correlograma da série. A análise visual nos fornecerá pistas acerca de quais os modelos a serem testados. Depois dessa indicação, o teste de Q de Ljung-Box será utilizado para verificar se os modelos estimados por mínimos quadrados possuem realmente ruído branco. Também, utilizaremos a estimação de HAC-Newey-West, por apresentar resultados robustos à heterocedasticidade.

A opção pelo modelo mais adequado obedecerá aos critérios de informação de Akaike (AIC) e de Schwarz(SIC), a fim de escolhermos o modelo mais parcimonioso (ENDERS, 1995).

Quanto aos modelos de suavização exponencial, parte da lógica é bastante semelhante. Algum conhecimento preliminar em séries temporais permite determinar que o comportamento delas apresenta, em geral, alguns padrões. Isto é, componentes. Geralmente verifica-se uma tendência, ou seja, a série segue determinada direção, crescente ou decrescente e não necessariamente linear. Sazonalidade, um padrão que se repete com certa periodicidade dentro de um ano. E, por último, ciclo. A repetição de um padrão, não dentro de um período fixo, ainda que relativamente regular (Ferreira, 2017). Reside aí a importância da decomposição anterior empreendida no item 2.

O método mais simples de suavização exponencial (SES) é adequado para séries temporais livres das componentes de tendência e sazonalidade. Já o método de Holt (SEH) mostra-se adequado para séries com tendência linear. Por último, a suavização exponencial de Holt-Winter (SHW) é o método mais indicado para séries que apresentam componente sazonal. Podendo ser aditivo ou multiplicativo. Uma vez que as séries aqui trabalhadas, em geral, apresentam sazonalidade e tendência, como demonstrado, cabe detalhar o método SHW. Ele consiste, basicamente, em modelar a série, a tendência e a sazonalidade, suavizando seus efeitos ao longo do tempo.

Modelo SHW aditivo:

$$L_t = \alpha(Z_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1}); 0 \leq \alpha \leq 1, t = m + 1, \dots, N \quad (2)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}; 0 \leq \beta \leq 1, t = m + 1, \dots, N \quad (3)$$

$$S_t = \gamma(Z_t + L_t - L_{t-1}) + (1 - \gamma)S_{t-m} ; 0 \leq \gamma \leq 1, t = m + 1, \dots, N \quad (4)$$

$$\hat{Z}_{t+h} = L_t + T_t h + S_{t+h-m} \quad (5)$$

Modelo SHW multiplicativo:

$$L_t = \alpha\left(\frac{Z_t}{S_{t-m}}\right) + (1 - \alpha)(L_{t-1} + T_{t-1}) ; 0 \leq \alpha \leq 1, t = m + 1, \dots, N \quad (6)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} ; 0 \leq \beta \leq 1, t = m + 1, \dots, N \quad (7)$$

$$S_t = \gamma\left(\frac{Z_t}{L_t - L_{t-1}}\right) + (1 - \gamma)S_{t-m} ; 0 \leq \gamma \leq 1, t = m + 1, \dots, N \quad (8)$$

$$\hat{Z}_{t+h} = (L_t + T_t h) S_{t+h-m} \quad (9)$$

Onde:

$\alpha$  representa o parâmetro de suavização

$\hat{Z}_{t+h}$  é a previsão da série com h períodos a frente.

$T_t$  modela a tendência

$S_t$  modela a sazonalidade

Tanto os modelos univariados ARMA, quanto os modelos de suavização exponencial são bastante simples, mas amplamente utilizados em séries semelhantes, sendo, por esse motivo, escolhidos. Consistindo o trabalho econométrico na estimação dos parâmetros deles, verificação, através dos testes, de sua robustez, principalmente no que diz respeito a ruídos e à comparação, através dos menores erros médios. Gerando a previsão.

### Uso recente do método econométrico

Os modelos aqui trabalhados costumam encontrar bastante aceitação em termos de usos para a política de transportes e na estimação em geral. Também, recentemente, têm sido objeto de uso na quantificação de efeitos da pandemia de Covid-19. Apenas para ficar no uso mais recente, entre 2019 e 2020, encontramos o artigo de Kufel (2020), o qual utilizou modelos ARIMA para prever o comportamento da propagação do vírus em países europeus. Do mesmo modo, AlzahraniIbrahim, Ebrahim e Fakih (2020), utilizaram a mesma categoria, determinada por Ceylan (2020). A busca por autores e artigos confirma o amplo uso do mesmo no tratamento e previsão da pandemia.

Já nos transportes, para o Brasil, as categorias de uso são diversas, passando pelo transporte hidroviário em (TAKASAKI, 2020). Por último, o modal rodoviário de Porto Alegre pode ser evidenciado por Scaletzky (2019). Comprovando o uso comum e amplo dos modelos propostos.

## Aplicação da Metodologia e Achados

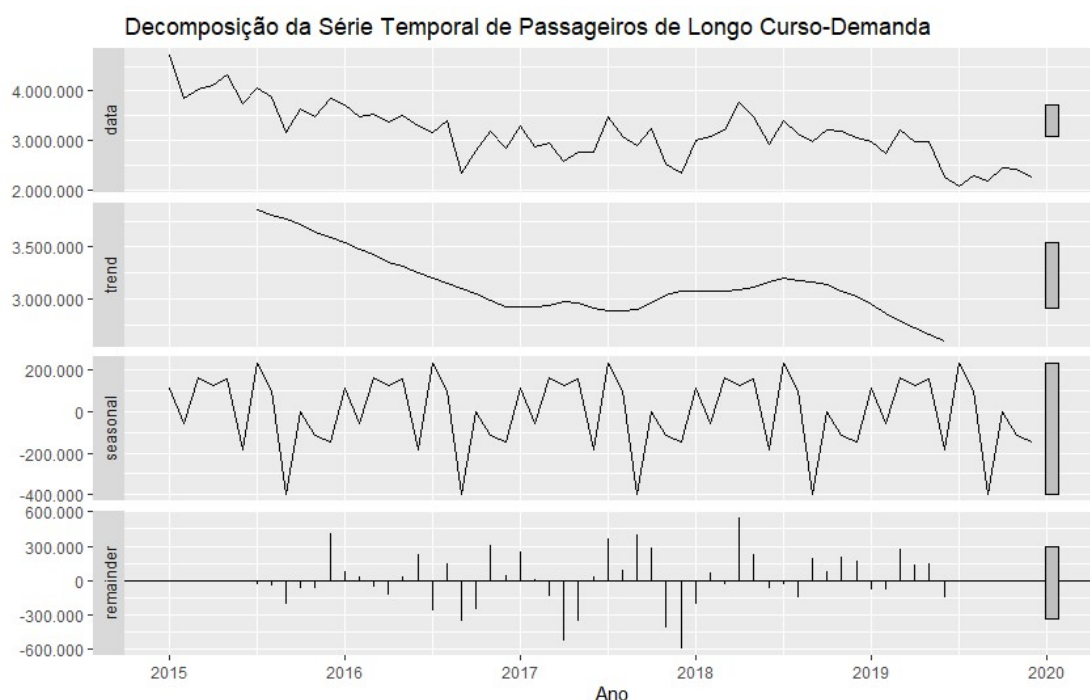
Para a metodologia proposta, o primeiro passo é a definição das variáveis de interesse. Uma vez que se busca analisar os impactos da pandemia de Covid-19 no equilíbrio econômico-financeiro, torna-se natural definir o número de passageiros, a fim de representar a demanda dos serviços, e a Receita Total para os sistemas analisados. Como advertido anteriormente, os dados mais robustos foram encontrados para a Demanda e Receita do Longo Curso e na Demanda de Passageiros da RMPA, com uma série temporal mais longa e mais estável. Selecionou-se o período entre janeiro de 2015 e dezembro de 2019.

Variáveis de Interesse:

- a) Receita Total mensal em valores constantes de dezembro de 2019 para o sistema de Longo Curso.
- b) Número de passageiros transportados mensal para o sistema de Longo Curso.
- c) Número de passageiros transportados mensal para a Região Metropolitana de Porto Alegre.

O passo seguinte consiste na decomposição da série temporal em seus componentes a fim de verificar a existência de tendência, sazonalidade e ciclo. Para tanto, utilizar-se-á a função *decompose* do pacote *stats v3.6.2* para o *software* livre *R*. Essa função, conforme a documentação do pacote, decompõe uma série temporal em componentes sazonais, de tendência e irregulares usando médias móveis. Lidando, ainda, com componente sazonal aditivo ou multiplicativo. Obtemos os seguintes resultados:

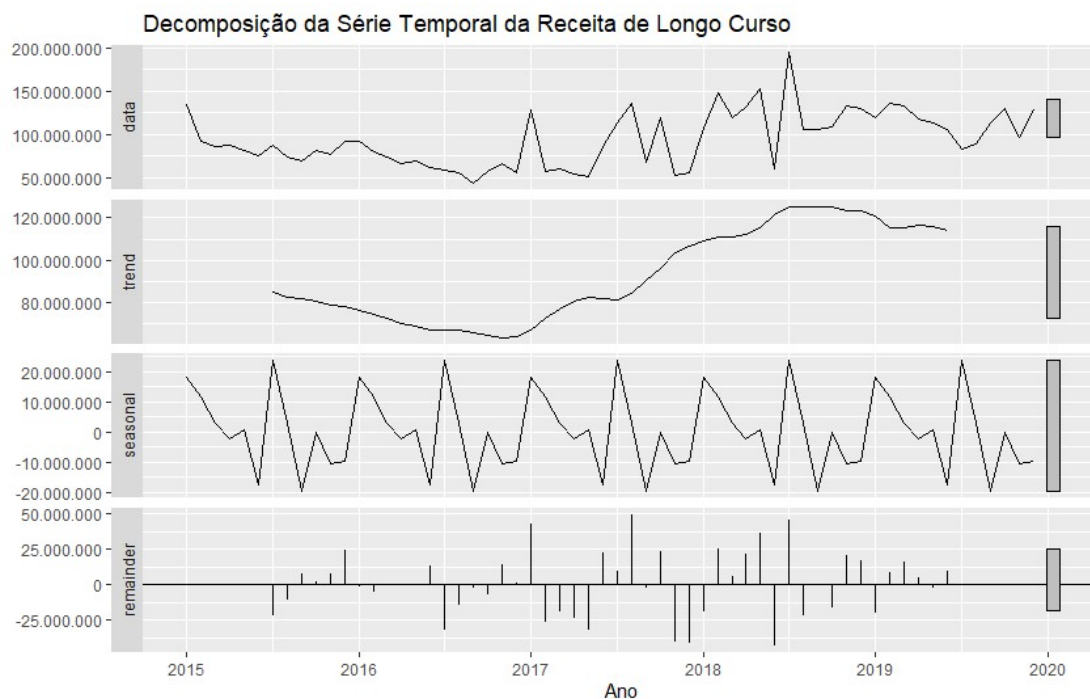
Gráfico3 – Decomposição do número de Passageiros Mensais Transportados no Longo Curso entre Janeiro de 2015 e Dezembro de 2019.



Fonte: Elaboração própria

A primeira janela do gráfico 3, identificada como data, representa a série temporal, enquanto a segunda, a terceira e a quarta, respectivamente, os componentes de tendência sazonalidade e erro. Para o gráfico, em termos de tendência, ficam evidentes três movimentos de queda: acentuada e quase linear entre 2015 e 2017, certa manutenção entre 2017 e 2019, com aceleração no último ano. Ou seja, pré-pandemia, a tendência já era de queda, sem a recuperação dos patamares anteriores a 2015. A saída de passageiros do sistema de longo curso estava em aceleração, sem perspectivas de recuperação. Quanto ao componente sazonal, observa-se regularidade, com picos no início e final dos períodos e na metade do ano, com sincronia dado o calendário de férias. Por último, o componente de erro (*remainder*) aponta que, ao longo da série, fatores externos, como choques, foram relevantes, encontrando eco na mesma.


Gráfico4 – Decomposição da Receita Total no Longo Curso entre janeiro de 2015 e dezembro de 2019.



Fonte: Elaboração própria

Procedendo a mesma análise, fica ainda mais evidente o descompasso entre a tendência na Receita e no número de passageiros para o Longo Curso. Nesse sentido, pós-revisão tarifária empreendida pela AGERGS em 2017, observamos tendência (*trend*) de recuperação dos valores e posterior estabilidade, mesmo com saída de passageiros do sistema. A sazonalidade dos valores de receita encontra certa consonância com a demanda, com os picos e vales aproximadamente iguais. O componente de erro também segue parâmetros semelhantes.

Gráfico5 – Decomposição do número de Passageiros Mensais Transportados no Longo Curso entre janeiro de 2015 e dezembro de 2019



Fonte: Elaboração própria

Por último, a decomposição dos componentes da série temporal para a Região Metropolitana de Porto Alegre pode, ainda mais, ressaltar tanto a política tarifária quanto o esgotamento desta e da capacidade de manutenção do equilíbrio econômico-financeiro dos serviços apenas na majoração de preços. Ao contrário do sistema de Longo Curso, a revisão, em que se analisam parâmetros de custos e demanda, ocorreu em 2014. Após, apenas reajustes, ou seja, recuperação da inflação foi implementada. Mesmo assim, a tendência (*trend*) da série é de queda constante quase linear. Novamente, sem perspectivas de reversão. A sazonalidade (*seasonal*) segue lógica diversa, uma vez que o início do ano diminui os deslocamentos nas cidades da RMPA, devido às férias de verão. O componente de erro repete os demais.

Uma vez identificados os componentes de presença de tendência e sazonalidade da série, decidiu-se testar modelos de Suavização Exponencial de Holt-Winters (SHW) e de Autorregressivos de Média Móvel com sazonalidade (SARIMA). A escolha parece razoável para a construção de um modelo de previsão univariado, uma vez que não dependem de teorias econômicas específicas.

A partir dos critérios de estimação, chegou-se nos modelos listados abaixo. O modelo de suavização exponencial de Holt-Winters, basicamente, consiste em estimar os parâmetros alpha, beta e gamma. Já o modelo SARIMA acaba por ser um pouco mais trabalhoso

necessitando, primeiramente, da análise de estacionariedade. Empreendido Dickey-Fuller Aumentado (ADF) ou de Philip-Perron(PP), verificou-se a necessidade de diferenciação da mesma. Após a análise dos correlogramas para tentar definir as defasagens a serem incluídas.

Feito isso, e definido o modelo que parecia mais razoável, testou-se para ausência de autocorrelação linear, heterocedasticidade condicional e normalidade, utilizando-se a função `tsdiag()` do pacote `stats v3.6.2`, não parecendo encontrar evidências das mesmas nos resíduos. Por último, os testes de Ljung-Box (1978), ARCH-LM(Engle,1982) e Jarque-Bera(1980) também pareceram apontar para bons diagnósticos. Seguindo o roteiro proposto por Ferreira, 2017.

De maneira resumida, os modelos escolhidos, em termos de parâmetros, podem ser explicitados como:

Tabela 1- Modelos estimados

Passageiros no Longo Curso		Receita no Longo Curso		Passageiros na RMPA	
SHW	SARIMA	SHW	SARIMA	SHW	SARIMA
alpha: 0.5165394	(1,1,0)(1,0,0)	alpha: 0.2812937	(1,1,1)(1,0,0)	alpha: 0.1266393	(1,1,2)(0,1,1)
beta: 0		beta: 0.0393183		beta: 0.3039751	
gamma: 0.2530235		gamma: 0		gamma: 0.4327318	

Fonte: Elaboração própria

De posse dos parâmetros estimados e da possibilidade de bons diagnósticos econométricos, podemos, então, empreender a previsão propriamente dita para o ano de 2020.

Cabe esclarecer preliminarmente que os modelos selecionados, tanto o de Holt-Winters (SHW) quanto os da SARIMA, preveem valores possibilitando um intervalo. Para tanto, as tabelas abaixo resumem as previsões dos modelos selecionados, partindo do pressuposto de que as colunas Forecast representam o centro da previsão. Já as colunas Hi 95 E Lo 95 demonstram os valores esperados, ou seja, previstos, com um intervalo de 95% de confiança para cima e para baixo. Funcionando como um cenário básico previsto (*forecast*), um otimista (HI95) e um pessimista (Lo 95).

Tabela 2- Previsão dos Modelos para os Passageiros no Longo Curso

Previsão dos Modelos para a Receita no Longo Curso						
	SHW			SARIMA		
	Lo 95	Forecast	Hi 95	Lo 95	Forecast	Hi 95
Janeiro	1.725.504	2.438.687	3.151.871	1.604.111	2.283.666	2.963.221
Fevereiro	1.392.730	2.195.438	2.998.146	1.400.786	2.206.419	3.012.051
Março	1.422.592	2.305.796	3.189.000	1.371.068	2.331.236	3.291.405
Abril	1.191.256	2.148.209	3.105.162	1.194.628	2.272.515	3.350.402
Mai	1.155.754	2.181.165	3.206.576	1.078.738	2.267.638	3.456.539
Junho	817.174	1.906.751	2.996.327	812.074	2.100.808	3.389.543
Julho	945.055	2.095.223	3.245.391	671.555	2.053.490	3.435.424
Agosto	757.207	1.964.930	3.172.654	639.948	2.108.990	3.578.033
Setembro	109.854	1.372.513	2.635.171	527.606	2.078.938	3.630.271
Outubro	378.515	1.693.815	3.009.115	512.138	2.141.587	3.771.036
Novembro	169.047	1.534.962	2.900.877	434.533	2.138.529	3.842.526
Dezembro	254.507	1.669.228	3.083.948	324.996	2.100.410	3.875.824
Total	10.319.194	23.506.717	36.694.238	10.572.181	26.084.226	41.596.275

Fonte: Elaboração própria

Tabela 3- Previsão dos Modelos para os Passageiros no Longo Curso

Previsão dos Modelos para a Receita no Longo Curso						
	SHW			SARIMA		
	Lo 95	Forecast	Hi 95	Lo 95	Forecast	Hi 95
Janeiro	71.996.362	129.631.387	187.266.413	58.246.543	112.101.844	165.957.146
Fevereiro	59.657.200	119.704.784	179.752.368	58.661.396	113.496.864	168.332.333
Março	52.729.177	115.271.294	177.813.412	56.764.484	113.378.068	169.991.652
Abril	45.283.923	110.399.368	175.514.812	55.156.475	113.416.666	171.676.858
Mai	47.065.020	114.829.606	182.594.192	53.555.835	113.423.786	173.291.737
Junho	38.897.913	109.384.670	179.871.427	52.006.170	113.439.278	174.872.386
Julho	43.014.483	116.293.848	189.573.213	50.521.640	113.481.053	176.440.467
Agosto	30.290.651	106.430.648	182.570.644	49.021.609	113.471.188	177.920.766
Setembro	23.302.904	102.369.311	181.435.718	47.520.377	113.426.437	179.332.496
Outubro	34.466.241	116.522.751	198.579.261	46.061.679	113.392.721	180.723.763
Novembro	27.641.246	112.749.614	197.857.982	44.730.099	113.456.583	182.183.068
Dezembro	41.830.712	130.050.889	218.271.066	43.302.540	113.396.692	183.490.844
Total	516.175.832	1.383.638.170	2.251.100.508	615.548.847	1.359.881.180	2.104.213.516

Fonte: Elaboração própria



Tabela 4- Previsão dos Modelos para os Passageiros na Região Metropolitana de Porto Alegre

Previsão dos Modelos para os Passageiros na Região Metropolitana de Porto Alegre						
	SHW			SARIMA		
	Lo 95	Forecast	Hi 95	Lo 95	Forecast	Hi 95
Janeiro	6.309.139	6.309.139	6.988.962	5.906.188	6.382.190	6.858.192
Fevereiro	5.677.985	5.677.985	6.367.014	5.344.210	5.781.817	6.219.423
Março	7.012.637	7.012.637	7.715.435	6.632.123	7.188.259	7.744.395
Abril	6.814.805	6.814.805	7.536.621	6.242.096	6.782.833	7.323.570
Mai	7.171.989	7.171.989	7.918.589	6.484.235	7.069.783	7.655.332
Junho	6.702.690	6.702.690	7.480.171	6.183.362	6.770.543	7.357.723
Julho	6.911.815	6.911.815	7.726.418	6.203.702	6.828.150	7.452.597
Agosto	7.270.173	7.270.173	8.128.130	6.447.766	7.140.435	7.833.105
Setembro	6.462.012	6.462.012	7.369.416	5.752.059	6.415.248	7.078.437
Outubro	7.065.403	7.065.403	8.028.119	6.113.361	6.873.105	7.632.849
Novembro	6.633.910	6.633.910	7.657.522	5.802.882	6.582.669	7.362.456
Dezembro	6.322.704	6.322.704	7.412.487	5.574.409	6.386.146	7.197.884
Total	80.355.262	80.355.262	90.328.884	72.686.393	80.201.178	87.715.963

Fonte: Elaboração própria

Destaca-se que alguns dos valores encontrados entre vários modelos são bastante próximos, outros nem tanto. Em média, entre os valores estimados, encontramos discrepância, quando comparados os valores mínimos com seus pares, o centro do intervalo com os centros e os valores máximos com os máximos, de cerca de 7,19%. Ainda que não prejudique a análise, no mínimo, torna-se necessário considerar e advertir para essa diferença.

A função *accuracy* do pacote *forecast v8.12* do *softwareR* permite um critério objetivo de comparação entre os modelos. Ela retorna o intervalo de medidas resumidas de precisão da previsão, sendo que elas foram definidas e discutidas em Hyndman e Koehler (2006). As medidas calculadas são Erro Médio (ME), Raiz do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE), Percentagem de Erro Média (MPE), Erro Percentual Médio Absoluto (MAPE), Erro Médio Absoluto Escalado (MASE) e Autocorrelação de erros no lag 1 (ACF1).

Dadas as características das séries e uma vez que as previsões, ainda que tenham diferido em cerca de 7%, apresentam valores relativamente próximos, os critérios de seleção dos modelos mais adequados foram o erro médio (ME) e a percentagem de erro média (MPE). Quando os valores apontavam diferente, o critério foi a raiz do erro quadrático médio (RMSE).

Tabela 5- Comparação entre os erros dos modelos

		ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Passageiros no Longo Curso	SHW	42.801,27	362.600,60	282.139,70	0,7557	9,9773	0,5026	0,1428
	SARIMA	45.802,31	343.817,10	256.997,10	- 2,1904	8,6256	0,8291	0,0703
Receita no Longo Curso	SHW	3.506.431,00	29.308.746,00	21.199.137,00	- 2,7301	22,0200	0,6200	0,0567
	SARIMA	130.747,70	27.247.762,00	21.075.219,00	- 7,1050	23,3187	0,6164	0,0260
Passageiros na RMPA	SHW	18.605,67	343.726,20	272.713,00	0,1992	3,5920	0,4560	0,1943
	SARIMA	4.341,13	257.249,20	202.841,90	- 0,0208	2,5719	0,3392	0,2974

Fonte: Elaboração própria

Da análise dos erros dos modelos percebe-se que os modelos de suavização exponencial de Holt-Winters tendem a errar para cima, isto é, sobrestimarem os valores observados. Já os modelos SARIMA propostos fazem o contrário, tendem a subestimar. Utilizando o critério delineado, para a variável passageiros no Longo Curso utilizar-se-á a previsão do modelo de suavização exponencial de Holt-Winters (SHW) demonstrado na tabela 2. Já para a Receita do Longo Curso e para os Passageiros da RMPA, os modelos SARIMA das tabelas 3 e 4.

Tabela 6- Cenários para os passageiros de Longo Curso

Mês	Previsão do Modelo SHW			Série Observada	Comparação entre os cenários		
	Lo 95	Forecast	Hi 95		Pior Cenário	Cenário Base	Cenário Otimista
Janeiro	1.725.504	2.438.687	3.151.871	2.392.694	667.190	45.993	759.177
Fevereiro	1.392.730	2.195.438	2.998.146	2.068.543	675.813	126.895	929.603
Março	1.422.592	2.305.796	3.189.000	1.311.712	110.880	994.084	1.877.288
Abril	1.191.256	2.148.209	3.105.162	433.943	757.313	1.714.266	2.671.219
Mai	1.155.754	2.181.165	3.206.576	552.741	603.013	1.628.424	2.653.835
Junho	817.174	1.906.751	2.996.327	587.050	230.124	1.319.701	2.409.277
Julho	945.055	2.095.223	3.245.391	602.084	342.971	1.493.139	2.643.307
Agosto	757.207	1.964.930	3.172.654	639.616	117.591	1.325.314	2.533.038
Setembro	109.854	1.372.513	2.635.171	728.516	618.662	643.997	1.906.655
Outubro	378.515	1.693.815	3.009.115	769.403	390.889	924.412	2.239.712
Novembro	169.047	1.534.962	2.900.877	770.090	601.043	764.872	2.130.787
Total	10.064.686	21.837.489	33.610.290	10.856.392	791.706	10.981.097	22.753.898

Fonte: Elaboração própria

Ao se analisar a comparação entre a série observada para o ano de 2020 e o cenário que os modelos previam, alguns efeitos da pandemia de Covid-19 podem ser verificados. Em

primeiro lugar, como dito anteriormente, o modelo prevê por intervalos, um cenário base (o centro da previsão), um limite inferior (algo como uma previsão mais pessimista, mas ainda dentro do esperado) e um limite superior (um bom desempenho, mas ainda dentro do intervalo de 95%). Lembrando que se consideraram os valores acumulados entre janeiro e novembro, pois os dados de dezembro ainda não estão completos.

Para a demanda de passageiros do sistema de Longo Curso, antes da pandemia, nos meses de janeiro e fevereiro, a situação encontrava-se entre o pior cenário previsto e o base. A partir de março, com as medidas de distanciamento e o recrudescimento da pandemia, os valores observados mostraram constância abaixo do pior cenário previsto. Essa situação começou a mudar, ainda que brevemente, a partir do mês de setembro. Em comparação ao pior que o modelo poderia prever, o cenário líquido ainda seria positivo no sentido de quase 800 mil passageiros, algo como 7% positivo. Ou seja, no acumulado do ano, o limite inferior do modelo trabalhava com 10.064.686, o que se verificou foram 10.856.392

Ainda em demanda do Longo Curso, o cenário base aponta para situação bastante diferente. Aconteceu a redução de 10.981.097 passageiros transportados. Ou algo como 51% dos passageiros que poderiam estar sendo transportados, já considerando a tendência de queda histórica. Grande parte desse efeito pode ser atribuído à pandemia de Covid-19 e às medidas de distanciamento social. Dado o histórico da série, esse valor constitui o melhor para a análise. Os valores mais otimistas, ou seja, o limite superior, mostram possibilidades ainda mais significativas, mas como já se esperava algum tipo de queda, não cabe se deter muito neles.

Tabela 7- Cenários para a Receita de Longo Curso

Mês	Previsão do Modelo SHW			Série Observada	Comparação entre os cenários		
	Lo 95	Forecast	Hi 95		Pior Cenário	Cenário Base	Cenário Otimista
Janeiro	58.246.543	112.101.844	165.957.146	139.997.039,40	81.750.496	27.895.195	25.960.107
Fevereiro	58.661.396	113.496.864	168.332.333	117.647.356,35	58.985.960	4.150.492	50.684.977
Março	56.764.484	113.378.068	169.991.652	45.238.001,55	11.526.482	68.140.066	124.753.650
Abril	55.156.475	113.416.666	171.676.858	6.947.818,93	48.208.656	106.468.847	164.729.039
Mai	53.555.835	113.423.786	173.291.737	11.908.816,76	41.647.018	101.514.969	161.382.920
Junho	52.006.170	113.439.278	174.872.386	10.531.571,93	41.474.598	102.907.706	164.340.814
Julho	50.521.640	113.481.053	176.440.467	10.255.875,63	40.265.764	103.225.177	166.184.591
Agosto	49.021.609	113.471.188	177.920.766	12.078.454,20	36.943.155	101.392.734	165.842.312
Setembro	47.520.377	113.426.437	179.332.496	14.684.607,05	32.835.770	98.741.830	164.647.889
Outubro	46.061.679	113.392.721	180.723.763	18.757.910,36	27.303.769	94.634.811	161.965.853
Novembro	44.730.099	113.456.583	182.183.068	17.348.534,27	27.381.565	96.108.049	164.834.534
Total	572.246.307	1.246.484.488	1.920.722.672	405.395.986	166.850.321	841.088.502	1.515.326.686

Fonte: Elaboração própria

A mesma análise pode ser empreendida para a Receita do Sistema de Longo Curso, utilizando os limites e o centro previsto pelos modelos, a fim de estimar os efeitos da

pandemia e das medidas necessárias. Aqui o cenário é bem diferente, mesmo o cenário mais pessimista não prevê a queda ocorrida. No pior cenário, a frustração de expectativa acumulada até novembro de 2020 para o sistema é da ordem de R\$ -166.850.321,00 ou algo como 29,15% da receita nesse cenário. A base que se poderia esperar acumularia diminuição de receita de R\$ -841.088.502, 00 ou -67,42 %. Novamente, os valores otimistas não comportam maiores análises. Deve-se ressaltar, entretanto, que a receita estava sendo prevista para os meses de janeiro e fevereiro, no cenário base, com relativa precisão, demonstrando que as medidas necessárias de distanciamento social, a partir de março, podem ter tido um papel fundamental nessa diferença.

Tabela 8- Cenários para os passageiros da RMPA

Mês	Previsão do Modelo SHW			Série Observada	Comparação entre os cenários		
	Lo 95	Forecast	Hi 95		Pior Cenário	Cenário Base	Cenário Otimista
Janeiro	5.906.188	6.382.190	6.858.192	6.538.875	632.687	156.685	- 319.317
Fevereiro	5.344.210	5.781.817	6.219.423	5.973.859	629.649	192.042	- 245.564
Março	6.632.123	7.188.259	7.744.395	5.201.892	- 1.430.231	- 1.986.367	- 2.542.503
Abril	6.242.096	6.782.833	7.323.570	2.221.804	- 4.020.292	- 4.561.029	- 5.101.766
Mai	6.484.235	7.069.783	7.655.332	2.906.027	- 3.578.208	- 4.163.756	- 4.749.305
Junho	6.183.362	6.770.543	7.357.723	3.208.357	- 2.975.005	- 3.562.186	- 4.149.366
Julho	6.203.702	6.828.150	7.452.597	3.071.033	- 3.132.669	- 3.757.117	- 4.381.564
Agosto	6.447.766	7.140.435	7.833.105	3.329.057	- 3.118.709	- 3.811.378	- 4.504.048
Setembro	5.752.059	6.415.248	7.078.437	3.593.198	- 2.158.861	- 2.822.050	- 3.485.239
Outubro	6.113.361	6.873.105	7.632.849	4.099.140	- 2.014.221	- 2.773.965	- 3.533.709
Novembro	5.802.882	6.582.669	7.362.456	4.092.978	- 1.709.904	- 2.489.691	- 3.269.478
Total	67.111.984	73.815.032	80.518.079	44.236.220	- 22.875.764	- 29.578.812	- 36.281.859

Fonte: Elaboração própria

Por último, a comparação entre os limites previstos pelo modelo selecionado e a série observada para o número de passageiros transportados na RMPA apontam que os meses de janeiro e fevereiro evidenciavam certa estabilidade com o cenário base previsto sendo bastante preciso. A partir de março, ocorreu quase que uma reversão completa. Mesmo o cenário mais pessimista apontou queda na ordem de -22.875.764 ou de -34,08% na demanda. Já o base, indicou -29.578.812 passageiros transportados do que o previsto pelo modelo ou ainda -40,08%. A marcação bem desenhada para o descompasso entre o previsto pelo modelo e os valores observados aponta para o fortalecimento da hipótese de que essas quedas foram, em grande parte, ocasionadas pela pandemia de Covid-19.

Considerando que, para o de 2019, a receita na Região Metropolitana de Porto Alegre, tendo como fonte o BI da AGERGS, era de R\$ 550.176.857,32, pode-se chegar à aproximação de receita não realizada para o sistema como algo entre R\$ 187.500.272,97 e R\$ 220.510.884,41.

Mesmo que se atribua apenas grande parte desses efeitos, os dois sistemas estudados, os quais representam cerca de 90% do transporte intermunicipal de passageiros do

Rio Grande do Sul, em termos de receita, apresentaram, em um cenário base, diminuição de receita esperada aproximada estimada em R\$ 1.061.599.386,41.

Frente a esse achado, corroboram-se as estimativas do Grupo de Trabalho de Infraestrutura, Logística e Mobilidade do Comitê de Dados do Rio Grande do Sul. O mesmo, em trabalho semelhante, estimava que, somando-se os custos e a queda na receita, os efeitos da pandemia sobre o sistema de transportes poderiam chegar a ser de cerca de 145 milhões para os meses de março, abril, maio e junho. Considerando-se uma perda média anualizada de 14,76% tanto na demanda, quanto na receita. O pior cenário daquele estudo contemplava a possibilidade de queda na demanda de cerca de 40%, verificou-se uma média de -45,17%, confirmando as piores previsões. Nesse cenário, naquele estudo, a frustração acumulada pelo sistema seria de cerca R\$ 1,3 bilhão.

## Conclusões

A pandemia de coronavírus, ocorrida no ano de 2020, ocasionou situações nunca vivenciadas em, pelo menos, cem anos. Torna-se difícil, inclusive, encontrar pontos de comparação e de convergência com o ocorrido, tanto nas medidas necessárias que se estabeleceram como forma de combate à pandemia como nos efeitos sociais e econômicos do vírus.

No setor de transportes, em especial o de transporte intermunicipal de passageiros, a situação acabou por ser ainda mais grave. As notórias dificuldades do sistema, tão ressaltadas recentemente, já demandavam soluções urgentes, reformulações e criatividade para a constante queda no número de usuários. A crise era sistêmica e já se esperava, para o ano de 2020, algum tipo de queda tanto de receita quanto de demanda.

Este trabalho objetivou servir como contribuição no estabelecimento de uma metodologia adaptada ao contexto. Frente à queda já esperada, como começar a separar os efeitos sistêmicos do fato imprevisto ocasionado pela pandemia? Visou, em última instância, servir ao debate de políticas públicas sobre o tema.

Para tanto, utilizaram-se séries temporais, as melhores disponíveis. Estudos mais completos podem ser realizados aprofundando as análises. Espera-se que o trabalho possa ser continuado e refinado.

Os modelos selecionados, através de critérios econométricos, demonstraram que o número de passageiros transportados no sistema de Longo Curso, isto é, a demanda, frente ao mais pessimista dos cenários, mesmo que tenha visto ao longo do ano de 2020 uma queda significativa, apresentou breve recuperação, ficando dentro do esperado. Já o cenário base, mais preciso e estável, nem otimista e nem pessimista, apontou uma queda na ordem 10.981.097 passageiros transportados. Ou algo como 51% da variável esperada. Sublinhando os efeitos da pandemia nessa variável.

Já a Receita do sistema de Longo Curso, em todos os cenários considerados, apresentou frustração de expectativa acumulada até novembro de 2020 entre R\$ -166.850.321,00 e R\$ -841.088.502, 00. Quando se pensa em termos percentuais, em um cenário base, a diferença de receita entre o que poderia ser previsto pelo modelo e o que ocorreu era de cerca de -67, 42%. Ou seja, o equilíbrio financeiro do sistema, devido em grande parte à pandemia de Covid-19, poderia restar prejudicado.

Por último, para a Região Metropolitana de Porto Alegre, quando se pensa em passageiros transportados, demanda, mesmo o cenário mais pessimista previsto sublinhou na ordem de -34,08% os efeitos em parte ocasionados pela Covid-19. Já o base, mais estável -29.578.812 usuários, ou -40, 08%.

Cabe uma última advertência, não se está afirmando de maneira categórica que toda a queda nas variáveis deva ser creditada à pandemia. Maiores estudos são necessários, e o refinamento dos modelos pode trazer resultados interessantes. Sublinha-se, entretanto, que a evidência empírica leva a crer que grande parte do descompasso entre o previsto pelos modelos e o realizado na série restou ocasionado pelas medidas necessárias tomadas de combate à propagação do vírus.

Nota-se que não foram estudados os custos. Aqui somente se trabalhava com expectativas previstas pelo modelo. Geralmente, em situações como essa, as empresas reagem diminuindo a oferta e contendo custos, reduzindo assim os prejuízos verificados. Para tanto, não se está aqui estimando diretamente prejuízos, somente frustrações de expectativa de Receita e de Demanda. O que, sem dúvida, prejudica o planejamento do setor, já apertado pela situação pré-pandêmica, com reflexos no equilíbrio econômico-financeiro. Por último, mesmo que se atribua apenas grande parte desses efeitos à crise e às medidas de distanciamento, a relevante frustração de receita esperada estimada em cerca de R\$ 1.061.599.386,41, já encontrava um sistema em dificuldades, e o equilíbrio pode ter sido afetado de maneira decisiva. As soluções, que já se faziam urgentes, agora podem se mostrar ainda mais. Espera-se que elas vislumbrem e contemplem, de maneira integrada, o financiamento do setor, a regularização, a remodelagem do sistema e o planejamento integrado com outros modais.

## Referências

ALZHRANIIBRAHIM,S.I; EBRAHIM,A.A.; AL-FAKIH,A. Forecasting the spread of the COVID-19 pandemic in Saudi Arabia using ARIMA prediction model under current public health interventions. Journal of Infection and Public Health. Volume 13, Issue 7, p. 914-919, 2020.

BOX, G.; JENKINS, G.; REINSEL, G. C. Time Series Analysis, Forecasting and Control. 3.ed. Englewood Cliffs:Prentice-Hall, 1994.

BUENO, R., Econometria de séries temporais. 2ª Ed. São Paulo: Cengage Learning, 2012.

- CEYLAN, Z., Estimation of COVID-19 prevalence in Italy, Spain, and France. *Science of The Total Environment*, volume 729, 2020.
- ENDERS, W., *Applied Econometric Time Series*. John Wiley & Sons, Inc. 1995.
- ENGLE, R. Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica*, v. 50, n. 4, p. 987–1007, 1982.
- FERREIRA, P. G. C. *Análise de séries temporais em R: Curso introdutório*. São Paulo, SP: GEN Atlas, 2018.
- HAMILTON, J., *Time Series Analysis*. Princeton: Princeton University Press, 1994.
- HYNDMAN, R.J.; KOEHLER, A.B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, p. 679-688, 2006.
- KUFEL, T. ARIMA-based forecasting of the dynamics of confirmed Covid-19 cases for selected European countries. *Journal of Equilibrium. Quarterly Journal of Economics and Economic Policy*, p. 182-204, 2020.
- SECCHI, L.. (2014). Leonardo. *Políticas Públicas: conceitos, esquemas de análise, casos práticos*. 2° Ed. São Paulo: Cengage Learning.
- SCALETZKY, H.L, A morte do transporte público - análise da sustentabilidade econômico-financeira do sistema de ônibus de Porto Alegre. Trabalho de Conclusão de Curso de Graduação. Escola de Engenharia- UFRGS, 2019.
- LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. *Biometrika*. v.65, p. 297–303, 1978.
- JARQUE, C. M.; BERA, A. K. Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics letters*, v. 6, n. 3, p. 255- 259, 1980.
- TAKASAKI, E. A. O novo modelo brasileiro de exploração ferroviária. 2014. 127 f., il. Dissertação (Mestrado em Economia do Setor Público)—Universidade de Brasília, Brasília, 2014.
- WOOLDRIDGE, J.M. *Introdução à econometria*. São Paulo: CENGAGE, 5.ed. 2018.