

PORTARIA ARTESP Nº 50, DE 22 DE MAIO DE 2025

Dispõe sobre a metodologia para apuração dos impactos decorrentes da pandemia de Covid-19 na receita de pedágio e sobre a recomposição do equilíbrio econômico-financeiro nos contratos de concessão rodoviária do Estado de São Paulo.

Capítulo 1 – Disposições Gerais

Artigo 1º - Esta Portaria estabelece a metodologia para mensuração dos impactos ocasionados pela pandemia de Covid-19 na receita tarifária com vistas à recomposição do equilíbrio econômico-financeiro dos contratos de concessão integrantes do Programa de Concessões Rodoviárias do Estado de São Paulo.

Artigo 2º - A presente Portaria se aplica aos contratos de concessão que se encontravam em operação comercial (cobrança de tarifa de pedágio) em qualquer mês no período compreendido entre março de 2020 e dezembro de 2022, excetuados os contratos que possuem critérios próprios de compartilhamento de risco de demanda.

Artigo 3º - O período de apuração dos impactos da pandemia de Covid-19 sobre o equilíbrio econômico-financeiro dos contratos de concessão se restringe ao período compreendido entre março de 2020 e dezembro de 2022, nos termos do estudo constante do Anexo 2 desta Portaria.

Capítulo 2 – Metodologia para medição dos impactos gerados pela pandemia de Covid-19 na receita tarifária

Artigo 4º - Entende-se como evento extraordinário, apto a desencadear a apuração de desequilíbrio econômico-financeiro de que trata esta Portaria, a variação de tráfego que exceda ou fique abaixo dos limites do intervalo de confiança de 95% (noventa e cinco por cento) em relação ao centro da projeção de tráfego ora proposta. Como consequência, as variações dentro desse intervalo serão tratadas como variações ordinárias e, portanto, não ensejarão a apuração de desequilíbrio econômico-financeiro dos contratos abrangidos nesta Portaria.

Artigo 5º - O impacto da pandemia de Covid-19 na receita tarifária será mensurado com base na diferença apurada mensalmente, em eixos equivalentes, entre os limites superiores/inferiores do intervalo de confiança do cenário projetado (contrafactual) e o tráfego efetivamente observado, conforme metodologia econométrica de séries temporais descrita no Anexo 1.

§1º - Entende-se como cenário contrafactual, para fins da apuração prevista no *caput*, aquele em que a pandemia hipoteticamente não teria ocorrido.

§ 2º - Para cálculo da projeção de tráfego do cenário contrafactual, serão adotadas as seguintes premissas:

1. o período a ser considerado na base de dados de tráfego é de 10 (dez) anos;

2. com o objetivo de eliminar distorções decorrentes de fatores transitórios, tais como o início de operação, incorporação de novos trechos de cobrança ou alterações na direcionalidade de tráfego, serão expurgados os dados de crescimento referentes aos anos iniciais de cada concessão e à entrada de operação dos novos trechos, conforme Quadro 1 do Anexo 1 desta Portaria;
3. para as Concessionárias cujas praças de pedágio apresentem menos de 2 (dois) anos de operação comercial até dezembro de 2019, deverão ser observados os critérios para a estimação do volume de tráfego do modelo econométrico e na projeção do cenário contrafactual detalhado no Anexo 3 desta Portaria;
4. os dados de tráfego utilizados na apuração deverão ser aqueles informados pelas Concessionárias contratadas e processados pela ARTESP, conforme o Quadro 1, do Anexo 1 desta Portaria.

Capítulo 3 – Mensuração do Desequilíbrio Econômico-Financeiro e Recomposição do Equilíbrio Contratual

Artigo 6º - A variação extraordinária do volume de tráfego por praça de pedágio será calculada a partir da multiplicação da variação extraordinária mensal, apurada por meio do modelo econométrico de séries temporais (Anexo 1), pela participação percentual de cada praça de pedágio no tráfego total anual no ano calendário de 2023.

Art. 7º - O impacto da pandemia de Covid-19 na receita tarifária deverá ser apurado a partir da multiplicação da variação extraordinária do volume de tráfego por praça de pedágio, calculada com base no artigo 6º desta Portaria, pela tarifa contratual média de cada praça de pedágio.

§ 1º - A mensuração do eventual desequilíbrio econômico-financeiro deverá ser realizada em processo administrativo próprio para cada contrato de concessão.

§ 2º - A tarifa contratual média de cada praça de pedágio será calculada com base na seguinte equação:

$$T_{média_{t,c,p}} = \frac{Arrecadação_{t,c,p}}{Eixos Equivalentes_{t,c,p}}$$

Onde:

$T_{média_{t,c}}$ = Tarifa contratual média no mês t da Concessionária c na praça de pedágio p .

$Arrecadação_{t,c}$ = Receita de pedágio auferida no mês t pela Concessionária c na praça de pedágio p .

$Eixos Equivalentes_{t,c}$ = volume de tráfego medido em eixos equivalentes no mês t da Concessionária c na praça de pedágio p .

§ 3º - Caso a receita tarifária utilizada para cômputo da arrecadação contemple os efeitos da mitigação da perda de receita por eixos suspensos, tais efeitos deverão ser expurgados do cálculo da tarifa contratual média de cada praça de pedágio.

Art. 8º - O desequilíbrio econômico-financeiro decorrente do impacto da pandemia de Covid-19 nos contratos de concessão rodoviária será apurado considerando os seguintes elementos:

I - Taxa de desconto (Taxa Interna de Retorno – TIR) contratual ou respectiva para o evento de desequilíbrio objeto desta Portaria, segundo regramento individual de cada contrato de concessão;

II - Tributos diretos e indiretos, conforme a legislação vigente;

III - Encargos regulatórios, como o ônus de fiscalização e a outorga variável, conforme percentual estabelecido em cada contrato de concessão.

Art. 9º - Caberá ao Poder Concedente a definição da modalidade a ser adotada para a recomposição do equilíbrio econômico-financeiro de cada contrato de concessão, levando-se em consideração os impactos sofridos em cada um deles.

Parágrafo Único – Antes da definição de forma definitiva da modalidade pelo Poder Concedente para a recomposição do equilíbrio econômico-financeiro, será concedido prazo para manifestação não inferior a 15 (quinze) dias à concessionária.

Capítulo 4 – Disposições Finais

Art. 10 - Eventuais situações ou especificidades não contempladas nesta Portaria e em seus anexos deverão ser avaliados de forma individualizada em cada processo administrativo pertinente.

Art. 11 - Esta Portaria entrará em vigor na data de sua publicação.

André Isper Rodrigues Barnabé
Diretor-Presidente

(Processo SEI nº 134.00033264/2024-64- Portaria ARTESP nº 50, de 22 de maio de 2025)

ANEXO 01 - METODOLOGIA DE CÁLCULO DO EFEITO DA PANDEMIA SOBRE A DEMANDA (TRÁFEGO E RECEITA DE PEDÁGIO)

Introdução

A construção do cenário contrafactual será realizada por meio da estimação de modelo econométrico de séries temporais, com a projeção do tráfego e da receita tarifária para o período compreendido entre março de 2020 e dezembro de 2022.

Modelos de séries temporais utilizam o comportamento histórico de uma variável como base para a construção de cenários prospectivos. Assim, considera-se que os valores passados de uma variável são a principal fonte de informação para a projeção de seu comportamento futuro.

Modelos univariados de séries temporais utilizam exclusivamente o histórico da variável de interesse para a estimação dos coeficientes e projeção. Um exemplo de modelo univariado é o modelo ARIMA^[1].

Por sua vez, modelos multivariados de séries temporais consideram duas ou mais variáveis para a estimação dos coeficientes e projeção. Esses modelos partem do pressuposto de que a inclusão de variáveis explicativas adicionais contribui para a estimação e projeção do comportamento de uma série temporal. Entre os modelos multivariados, destaca-se o Modelo de Vetor Autorregressivo (VAR^[2]).

Os modelos VAR são amplamente utilizados por autoridades monetárias, pesquisadores e analistas do mercado financeiro, especialmente por sua flexibilidade, que permite a inclusão de variáveis sem a necessidade de especificar qual delas é dependente e quais são independentes. Nesse sentido, conforme Hyndman e Athanassopoulos (2018) e Bueno (2020), os modelos VAR estabelecem relações de feedback, tratando as variáveis como se influenciassem mutuamente, tanto por seus valores defasados quanto contemporâneos

Assim sendo, este anexo tem por objetivo descrever detalhadamente a metodologia de séries temporais que está sendo proposta pela ARTESP para apurar o eventual de desequilíbrio econômico-financeiro relacionado à perda de receita em decorrência da pandemia de Covid-19 nos contratos abrangidos no Programa de Concessão Rodoviária do Estado de São Paulo.

Especificação do Modelo e Variáveis Selecionadas

Formalmente, estima-se um modelo VAR cuja equação de interesse pode ser representada da seguinte forma:

$$Y_{it} = \mu + \sum_{j=1}^p \phi_{ij} Y_{i(t-j)} + \sum_{j=0}^q \gamma_{ij} Z_{i(t-j)} + \sum_{j=1}^r \delta_{ij} D_{ij} + \epsilon_{it}$$

Onde:

i = índice que indica a série temporal considerada relacionada a determinada Concessionária

t = índice que indica o período (mês)

μ = constante/intercepto

Y_t = volume de eixos equivalentes da Concessionária i no mês t

ϕ_{ij} = Constante que indica a relação entre a variável explicativa Y_i com suas defasagens p no tempo

Z_t = índice de atividade econômica que indica a variável explicativa/exógena do modelo

γ_{ij} = constante que estabelece a relação entre a variável exógena e suas defasagens q e a variável Y_i que se pretende estimar

D_t = Variáveis Dummies do mês t para a Concessionária i empregadas no modelo
 ∂_i = constante que indica a relação entre as variáveis Dummies e a variável endógena Y_i .
 ϵ = erro do modelo

Para estimação do modelo, foram consideradas as seguintes variáveis:

- Tráfego medido pelo volume de eixos equivalentes [3]
- Índice de Atividade Econômica do Banco Central (IBC-br) [4]
- Variável Dummy para o período de cobrança de eixos suspensos entre agosto de 2013 e maio de 2018
- Variável Dummy para a greve dos caminhoneiros em maio de 2018
- Variável Dummy calendário para controle da sazonalidade

A escolha de incluir o IBC-br como variável explicativa justifica-se pela forte relação entre o tráfego e a atividade econômica. A evolução do PIB está associada à circulação de pessoas e mercadorias, o que impacta diretamente o tráfego nas rodovias concedidas.

O PIB calculado a partir das contas nacionais divulgadas pelo IBGE [5] possui uma periodicidade trimestral, ao passo que o tráfego nas rodovias é comumente apresentado na periodicidade mensal. Neste sentido, uma alternativa possível seria utilizar o PIB mensal, calculado pelo Banco Central do Brasil (BCB) a partir das Contas Nacionais do IBGE, que poderia ser deflacionado por um deflator mensal, como por exemplo o IPCA. Todavia, exercícios econométricos preparatórios indicam que o PIB mensal deflacionado pelo IPCA não constitui uma série adequada para representar a atividade econômica como variável exógena no modelo proposto.

Neste sentido, optou-se pela utilização do IBC-br calculado pelo BCB. Exercícios econométricos preparatórios indicam forte correlação e relação de integração entre o tráfego e o IBC-br.

Adicionalmente, foram incluídas no modelo variáveis *dummies* para capturar o efeito das quebras estruturais geradas nas séries de tráfego geradas pelo período de cobranças de eixos suspensos e pela greve dos caminhoneiros. Exercícios econométricos preparatórios com base na função *seas* [6] do pacote *seasonal* do software R indicam a presença de quebra estrutural na série de tráfego em decorrência dos eventos supracitados.

Finalmente, a inclusão de variável *dummy* calendário justifica-se pelo forte componente sazonal das séries de tráfego.

O **Quadro 1** a seguir apresenta as Concessionárias que estão sendo consideradas para aplicação da metodologia aqui apresentada:

Quadro 1 – Concessionárias com operação comercial durante o prazo considerado nesta Portaria

Concessionária	Fase (Licitação)*	Base de Dados de Tráfego
Autoban	1ª	jan/2010 – fev/2020
Tebe	1ª	jan/2010 – fev/2020
Intervias	1ª	jan/2010 – fev/2020
Rota das Bandeiras	2ª	jul/2011 – fev/2020
Triângulo do Sol	1ª	jan/2010 – fev/2020
Renovias	1ª	jan/2010 – fev/2020
ViaOeste	1ª	mar/2010 – fev/2020
Colinas	1ª	jan/2010 – fev/2020
Cart	2ª	jul/2011 – fev/2020

ViaRondon	2ª	jul/2011 – fev/2020
SPVias	1ª	jan/2010 – fev/2020
Rodovias do Tietê	2ª	jul/2011 – fev/2020
Ecovias	1ª	jan/2010 – fev/2020
Ecopistas	2ª	jul/2011 – fev/2020
Rodoanel	2ª	jul/2011 – fev/2020
SPMar	2ª	jul/2012 – fev/2020
Rodovia dos Tamoios	3ª	Jul/2016 – fev/2020
Entrevias**	4ª	jan/2010 – fev/2020
ViaPaulista**	4ª	jan/2010 – fev/2020
Eixo**	4ª	jan/2011 – fev/2020

*
Classificação
não oficial
utilizada no
âmbito desta
Portaria.
** Histórico
de tráfego
das praças
do sistema
remanescente

Cumprir destacar que o **Quadro 1** contém apenas a relação das Concessionárias que operaram comercialmente em qualquer mês do período abrangido por esta Portaria (mar/20 – dez/22). Contudo, a caracterização da pandemia de Covid-19 como evento de desequilíbrio em cada contrato dependerá da análise jurídica, contratual e regulatória realizada pelas áreas competentes da ARTESP.

Para as Concessionárias das 1ª e 4ª fases considerou-se a amostra com dados entre janeiro de 2010 até fevereiro de 2020. Optou-se por expurgar os dados dos primeiros anos de operação comercial das praças dessas Concessionárias, uma vez que foram observadas diversas quebras estruturais nas séries de tráfego, decorrente de fatores como: efeito *ramp up*, mudança da direcionalidade, início de operação de novo trecho, abertura ou encerramento da operação de praças de pedágio. A inclusão da amostra anterior a 2010 resultaria em aumento significativo do ruído na série temporal sem oferecer benefícios substanciais (novas informações) para a projeção do tráfego no cenário contrafactual.

Por seu turno, as Concessionárias da segunda fase iniciaram a operação comercial entre o segundo semestre de 2008 e 2009. Assim, adotando metodologia análoga desconsiderando os primeiros anos de operação comercial, chega-se à data proposta de julho de 2011 para início da amostra da série de tráfego que será considerada para projeção para os demais contratos de concessão.

Estimação do Modelo

A estimação e a previsão em séries temporais dependem fundamentalmente das propriedades estatísticas das variáveis de interesse. Nesse diapasão, insere-se a avaliação em relação a estacionariedade das séries de tempo. Segundo Bueno (2010), uma variável é considerada estacionária quando possui média, variância e covariância constante ao longo do tempo, isto é, flutua em torno de uma mesma média. Em outros termos, séries estacionárias não possuem tendência e sazonalidade, apresentando, assim, apenas um termo aleatório^[7]. Assim, se as variáveis do modelo forem estacionárias, é possível realizar a estimação e a previsão do comportamento dessa variável para períodos futuros.

Caso contrário, se a série temporal possuir tendência e/ou sazonalidade ela será não estacionária, de modo que apresentará média, variância e covariância não constantes ao longo do tempo. Deste modo, caso as boas práticas estatísticas e econométricas não sejam realizadas, a estimação e a previsão de séries temporais não estacionárias podem resultar em uma situação conhecida na literatura como *regressão espúria*^[8].

De modo geral, séries não estacionárias devem ser diferenciadas para torná-las estacionárias. Contudo, a diferenciação pode gerar a perda de informações relevantes da série temporal. Nesse sentido, uma possível solução centra-se na verificação se as variáveis consideradas no modelo multivariado, mesmo que não estacionárias, possuam uma relação de longo prazo, isto é, se são cointegradas^[9].

Nesses termos, segundo Bueno (2020):

[...] se séries de tempo não estacionárias tem uma dinâmica em comum, no sentido que será dado neste capítulo, pode-se especificar um modelo VAR mais completo denominado vetor de correção de erros – VECM. Esse modelo possui significado econômico, pois pode-se dizer que suas variáveis, em virtude da dinâmica comum, têm um componente de longo prazo e um de curto prazo.

[...]

A teoria da cointegração preocupa-se, então, com dois pontos fundamentais. O primeiro é testar os resíduos u_t , para constatar tratar-se de uma variável estacionária. O segundo ponto é, dado que u_t é estacionário, usar essa informação para ajustar melhor o modelo VAR, denominado por causa desse ajuste de quase-VAR. Quando se utiliza a informação decorrente desse fato, tem-se o modelo VECM, em que se incorpora o erro de equilíbrio, daí a denominação de modelo vetor de correção de erros.

Dentre os métodos de verificação de cointegração entre séries temporais, destaca-se o proposto por Johansen (1991) a qual permite estimar o VECM simultaneamente aos vetores de cointegração.

Assim sendo, com base no protocolo proposto por Pfaff (2008), a construção do cenário contrafactual proposto nesta Portaria baseia-se nos seguintes passos para estimação do modelo econométrico:

1. Análise exploratória para identificação de *outliers* ou dados discrepantes;
2. Aplicação dos testes Augmented Dickey-Fuller (ADF), Phillips-Perron (PP) e Kwiatkowski-Phillips-Schmidt-Shin (KPSS) para verificar a presença de raiz unitária e, conseqüentemente a estacionariedade das séries temporais das variáveis eixos equivalentes e IBC-br;
3. Seleção de defasagens (*lags*) por critério de informação^[10];
4. Realização do teste de cointegração de Johansen^[11] pelo máximo autovalor e pela estatística do traço. Caso não haja pelo menos um vetor de cointegração entre as variáveis do modelo, voltar ao passo 3 para ajuste do número de *lags*;
5. Estimação do modelo VAR^[12] com as variáveis em nível;
6. Realização de testes de estabilidade (Autocorreção, Normalidade e Heterocedasticidade condicional^[13]) para verificação se os resíduos do modelo se comportam como ruído branco. Caso contrário, voltar ao passo 3 para ajuste do número de *lags*;
7. Realizar projeção para a série de eixos equivalentes;
8. Estimação do Intervalo de Confiança de 95%.

Foi adotado o intervalo de confiança de 95% por convenção e pelo fato de que, em grande medida, tal percentual está associado com o nível de significância usual de 5%. Considera-se que variações do tráfego abaixo do limite inferior ou acima do limite superior do intervalo de confiança são de baixa probabilidade de ocorrência e, desse modo, podem ser consideradas como variações extraordinárias cujo impacto releva-se excepcional na execução do contrato de concessão e, portanto, passível de reequilíbrio.

A este respeito, destaca-se a Resolução nº 5.954 de novembro de 2021 da Agência Nacional de Transportes Terrestres (ANTT) que tratou do reequilíbrio da pandemia de Covid-19 nos contratos de concessão do governo federal.

Nesse sentido, o impacto negativo ou positivo da pandemia no tráfego e na receita tarifária será mensurado com base nas equações abaixo:

$$\Delta \text{ Negativa} = Ve_{\text{observado}} - Li$$

$$\Delta \text{ Positiva} = Ve_{\text{observado}} - Ls$$

Onde:

$\Delta \text{ negativa}$ = variação extraordinária negativa do tráfego (perda de tráfego)

$\Delta \text{ positiva}$ = variação extraordinária positiva do tráfego (ganho de tráfego)

Ve = volume mensal de eixos equivalentes observado

Li = limite inferior do intervalo de confiança

Ls = limite superior do intervalo de confiança

Considerações Adicionais

Este Anexo apresentou as premissas e a metodologia de séries temporais proposta pela ARTESP para apurar o eventual de desequilíbrio econômico-financeiro decorrente da perda de receita de pedágio gerada pela pandemia de Covid-19 nos contratos de concessão do Estado de São Paulo entre março de 2020 e dezembro de 2022.

O modelo adotado tem por princípio construir um cenário contrafactual assumindo a hipótese que a pandemia não tivesse ocorrido. Com base na projeção do cenário central e das bandas do intervalo de confiança, é possível confrontá-lo com os dados observados para mensuração do impacto extraordinário da pandemia na receita de pedágio das Concessionárias.

Por fim, destaca-se que a ARTESP utilizará o *software* R para modelagem e previsão do tráfego e da receita tarifária no âmbito do objeto desta Portaria. Neste sentido, o Anexo 04 apresenta um exemplo de código do R com aplicação da metodologia proposta nesta Portaria.

Referências Bibliográficas

BUENO, R. L. S. **Econometria de Séries Temporais**. 2ª Edição. São Paulo, Cengage Learning, 2020.

JOHANSEN, S. Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models. **Econometrica**, vol. 59, nº 6, p. 1551-1580, 1991.

HYNDMAN, R.J., ATHANASOPOULOS, G. **Forecasting**: principles and practice. 2nd edition. Melbourne – Australia: OTexts, 2018. Disponível em: <<https://otexts.com/fpp2/>>. Acesso em: nov. 2024.

PFAFF, B. **Analysis of Integrated and Cointegrated Time Series with R**. 2ª Edição. New York: Springer, 2008.

WOOLDRIDGE, J.M. **Introdução à Econometria**: uma abordagem moderna. Tradução da 6ª edição norte-americana. São Paulo: Cengage Learning, 2016.

ANEXO 02 - DETERMINAÇÃO DA DATA FIM DO IMPACTO EXTRAORDINÁRIO DA PANDEMIA NA RECEITA DE PEDÁGIO

Este Anexo apresenta a metodologia empregada pela ARTESP para a delimitação do período em que serão apurados eventuais impactos da pandemia de COVID-19 sobre os volumes de tráfego das concessões rodoviárias estaduais sob sua regulação.

O Índice ABCR é calculado com base no fluxo total de veículos que transpuseram as praças de pedágio, considerando exclusivamente o tráfego nas rodovias administradas sob concessão. O cálculo do índice é efetuado mensalmente a partir dos dados de fluxo de cada concessionária, sendo gerado um número-índice consolidado para o país (índice agregado Brasil), bem como para os estados de São Paulo e Rio de Janeiro^[14].

Com o objetivo de analisar o comportamento do tráfego agregado nas rodovias do estado de São Paulo, comparando-o com o que seria esperado na ausência dos impactos decorrentes da pandemia de Covid-19, e tomando como referência o comportamento observado antes do início da pandemia, aplica-se neste Anexo a metodologia econométrica de séries temporais apresentada no Anexo 01 para a série histórica de tráfego do Índice ABCR agregado do estado de São Paulo.

Especificou-se um modelo VAR com as variáveis Índice ABCR e Índice de Atividade Econômica do Banco Central (IBC-br). Foram adicionadas variáveis *dummies* para capturar no impacto o período de cobrança de eixos suspensos, da greve dos caminhoneiros de 2018, além de filtros para controle da sazonalidade.


Após a análise das possíveis observações discrepantes, foram conduzidos testes de raiz unitária (ADF, KPSS e PP) para verificar a estacionariedade das séries temporais. Em seguida, realizou-se testes de integração para as variáveis endógenas do modelo. Para a variável Índice ABCR, os testes estatísticos ADF e PP indicam que a série é estacionária em nível. Apenas o teste KPSS indicou que o Índice ABCR é estacionário em primeira diferença. Por seu turno, em relação a variável relacionada à atividade econômica (IBC-br), os testes ADF, KPSS e PP indicam que a série é estacionária na primeira diferença.

Após especificação inicial realizou-se o teste de cointegração de Johansen pelo máximo autovalor e para a estatística do traço. Os testes oferecem forte evidência para presença de pelo menos um vetor de cointegração entre as variáveis do modelo: tráfego e atividade econômica (ABCR e IBC-br).

Em seguida, como as variáveis apresentam vetor de cointegração, modelou-se o VAR para as variáveis em nível e, após realização de testes de estabilidade dos resíduos do modelo (autocorrelação, normalidade e heterocedasticidade), foram geradas previsões para o período subsequente ao início da pandemia de Covid-19, acompanhadas pelos intervalos de confiança de 95%.

Assim sendo, a figura a seguir exibe a série observada do número-índice do Índice ABCR no estado de São Paulo, juntamente com as bandas estimadas do intervalo de confiança.


Figura 1 - Valores observados e limites do intervalo de confiança projetado para o Índice ABCR-SP – total de veículos



Inicialmente, é importante observar que valores observados fora dos limites do intervalo de confiança indicam variações extraordinárias no tráfego. Observa-se que a pandemia de COVID-19 exerceu impacto significativo no tráfego do setor em 2020 e em menor magnitude em 2021. Ao longo do segundo semestre de 2022 o índice observado parece se estabilizar próximo da banda inferior do intervalo de confiança, indicando que a pandemia deixou de exercer impacto extraordinário sobre a demanda de pedágio nas rodovias concedidas do Estado de São Paulo.

A este respeito, a figura 2 abaixo apresenta a variação percentual entre o IBCR mensal observado e a banda inferior do intervalo de confiança estimado:

Figura 2 – Variação Percentual entre o Índice ABCR observado e a estimativa da banda inferior do intervalo de confiança



Desse modo, conclui-se que o mês de dezembro de 2022 surge como marco temporal para a cessação dos impactos extraordinários da pandemia nas praças de pedágio do estado de São Paulo.

ANEXO 03 – CRITÉRIOS DE APURAÇÃO DO IMPACTO NAS PRAÇAS DE PEDÁGIO QUE NÃO POSSUEM HISTÓRICO SIGNIFICATIVO DE TRÁFEGO

Este Anexo apresenta a metodologia empregada para estimar o impacto da pandemia de Covid-19 na receita tarifária dos contratos contemplados no Programa de Concessão Rodoviária do Estado de São Paulo.

Considera-se, inicialmente, duas situações:

- i. *Contratos de Concessão que possuem Sistema Remanescente*
- ii. *Contratos de Concessão que não possuem Sistema Remanescente*

Para a situação ii descrita acima, a projeção do tráfego considerará o maior número de observações possíveis, incluindo os primeiros meses de operação comercial, excluindo apenas *outliers*.

Por seu turno, para os contratos de concessão descritos na situação i considerar-se-á o seguinte procedimento de apuração do impacto da pandemia:

Inicialmente, observa-se a distribuição do tráfego do Sistema Remanescente e do Sistema Existente durante 12 (doze) meses para os quais a pandemia de Covid-19 não esteja exercendo efeito significativo na receita tarifária da Concessionária.

Segundo exercício apresentado no Anexo 2, a pandemia de Covid-19 exerceu impacto relevante no volume de tráfego do Programa de Concessão Rodoviária do Estado de São Paulo até dezembro de 2022. Desse modo, assume-se que no exercício de 2023 a pandemia de COVID-19 não exerceu efeito significativo sobre o tráfego/receita das Concessionárias. Assim, considerou-se o exercício de 2023 (janeiro a dezembro) como período livre do efeito da pandemia para observação da distribuição do tráfego dos Sistemas Existente e Remanescente.

A partir dessa observação, calcula-se a participação percentual média do volume de tráfego das praças do Sistema Existente relativamente ao volume de tráfego do Sistema Remanescente, conforme fórmula abaixo:

$$P\%T_{2023} = \frac{\sum \text{Eixos Equivalentes}_{SE, 2023}}{\sum \text{Eixos Equivalentes}_{SR, 2023}}$$

Onde:

$P\%T$ = participação percentual do tráfego do Sistema Existente em relação ao tráfego do Sistema Remanescente em 2023

$\text{Eixos Equivalentes}_{SE}$ = somatório dos eixos equivalentes das praças de pedágio que compõe o Sistema Existente em 2023

$\text{Eixos Equivalentes}_{SR}$ = somatório dos eixos equivalentes das praças de pedágio que compõe o Sistema Remanescente em 2023

Esta distribuição do tráfego será utilizada como referência para mensuração do impacto da pandemia de Covid-19 no tráfego/receita das praças de pedágio do Sistema Existente para as quais não há série histórica de dados disponível.

Em seguida, após aplicação da metodologia do Anexo 01 será calculada a variação mensal total do tráfego em decorrência da pandemia de Covid-19 do Sistema Remanescente.

Assim, a estimativa da variação de tráfego do Sistema Existente será apurada a partir da equação abaixo:

$$\Delta \text{extraordinária}_t = \sum \Delta \text{extraordinária}_{SR,t} * P\%T_{2023}$$

Onde:

Δ extraordinária $_t$ = variação extraordinária do tráfego do Sistema Existente no mês "t".

Δ extraordinária $_{SR}$ = variação extraordinária do tráfego em eixos equivalentes do Sistema Remanescente no mês "t".

$P\%T_{, 2023}$ = participação percentual do tráfego do Sistema Existente em relação ao tráfego do Sistema Remanescente em 2023.

Em outros termos, como não há série história suficiente para realização de exercício econométrico de séries temporais de acordo com o Anexo 01 para as praças do Sistema Existente, adotou-se um procedimento simplificado que procura estimar a perda extraordinária da receita nessas praças em decorrência da pandemia de Covid-19. O referido procedimento entende que a observação da distribuição do tráfego em um período de um ano sem a influência significativa da pandemia pode ser utilizada como referência para mensuração do impacto nestas praças.

ANEXO 04 – EXEMPLO DE SCRIPT DO SOFTWARE R COM APLICAÇÃO DA METODOLOGIA ECONOMÉTRICA DE SÉRIES TEMPORAIS PROPOSTA NESTA PORTARIA

Carregando pacotes -----

library(readr)

library(readxl)

library(sidrar)

library(rbcbr)

library(dplyr)

library(lubridate)

library(tsibble)

library(RcppRoll)

library(fabletools)

library(feasts)

library(tidyr)

library(ggplot2)

library(fable)

library(urca)

library(vars)

library(purrr)

library(forecast)

library(aod)

library(stringr)

library(seasonal)

library(writexl)

library(dplyr)

library(seasonalview)

library(openxlsx)

library(tseries)

```

# Carregando dados -----

#Tráfego (dados offline)

LXX_dados <- read_xlsx ("LXX_concessionaria.xlsx") |>

rename (date = data) |>

mutate (date = yearmonth(date)) |>

as_tsibble (index = date) |>

filter (date >= as.Date("2010-01-01") & date <= as.Date("2023-12-31"))


#IBC_BR (dados online)

data_inicial <- "2010-01-01"

data_final <- "2023-12-31"

ibc_br <- rbcbr::get_series(

code = c("ibc_br" = 24364),

start_date = data_inicial,

end_date = data_final

) |>

mutate (date = yearmonth(date)) |>

as_tsibble (index = date)


#Agrupando base de dados na mesma Tsibble


dados <- purrr::reduce (

.x = list (LXX_dados, ibc_br),

.f = full_join, by = "date")


#Visualizando os dados

dados |>

```

```

tidyr::pivot_longer(cols = ~"date") |>

fabletools::autoplot(value) +

ggplot2::facet_wrap(facets = ~name, scales = "free") +

ggplot2::theme(legend.position = "none")


# Separação da amostra -----


# Amostra de teste

dados_teste <- dados |>

filter (date >= as.Date("2019-03-01") & date <= as.Date("2020-02-28"))


# Amostra de treino

dados_treino <- dados |>

filter (date >= as.Date("2010-01-01") & date <= as.Date("2019-02-28"))


# Amostra previsão

dados_pre_covid <- dados |>

filter (date <= as.Date("2020-02-28"))


# Amostra cenário contrafactual

dados_contrafactual <- dados |>

filter (date >= as.Date("2020-03-01") & date <= as.Date("2023-12-31"))


# Criando variáveis dummies -----


dummies <- dados |>

mutate(

dummy_suspensos = ifelse(date >= as.Date("2013-08-01") & date <= as.Date("2018-05-31"), 1, 0),

dummy_greve_maio = ifelse(date >= as.Date("2018-05-01") & date <= as.Date("2018-05-31"), 1, 0),

.keep = "used"

```

```
) |>
```

```
mutate (date = yearmonth(date)) |>
```

```
as_tsibble (index = date)
```

```
dummies_treino <- dummies |>
```

```
filter(date <= as.Date("2019-02-28"))
```

```
dummies_teste <- dummies |>
```

```
filter(date >= as.Date("2019-03-01") & date <= as.Date("2020-02-28")) |>
```

```
as.data.frame()|>
```

```
dplyr::select(-date) |>
```

```
as.matrix()
```

```
dummies_pre_covid <- dummies |>
```

```
filter(date <= as.Date("2020-02-28"))
```

```
dummies_contrafactual <- dummies |>
```

```
filter (date >= as.Date("2020-03-01")) |>
```

```
as.data.frame()|>
```

```
dplyr::select(-date) |>
```

```
as.matrix()
```

```
# Ordem de Integração período total -----
```

```
# Verifica ordem de integração iterativamente (ADF)
```

```
adf1 <- ndiffs(x = dados$eixos_equivalentes, test = "adf", type = "level")
```

```
adf2 <- ndiffs(x = dados$sibc_br, test = "adf", type = "level")
```

```
adf3 <- ndiffs(x = dados$eixos_equivalentes, test = "adf", type = "trend")
```

```
adf4 <- ndiffs(x = dados$sibc_br, test = "adf", type = "trend")
```

```
ordem_integracao <- c(adf1, adf2, adf3, adf4)
```

```
ordem_integracao
```

```
# Verifica ordem de integração iterativamente (KPSS)
```

```
kpss1 <- ndiffs(x = dados$eixos_equivalentes, test = "kpss", type = "level")
```

```
kpss2 <- ndiffs(x = dados$ibc_br, test = "kpss", type = "level")
```

```
kpss3 <- ndiffs(x = dados$eixos_equivalentes, test = "kpss", type = "trend")
```

```
kpss4 <- ndiffs(x = dados$ibc_br, test = "kpss", type = "trend")
```

```
ordem_integracao_kpss <- c(kpss1, kpss2, kpss3, kpss4)
```

```
ordem_integracao_kpss
```

```
# Verifica ordem de integração iterativamente (PP)
```

```
pp1 <- ndiffs(x = dados$eixos_equivalentes, test = "pp", type = "level")
```

```
pp2 <- ndiffs(x = dados$ibc_br, test = "pp", type = "level")
```

```
pp3 <- ndiffs(x = dados$eixos_equivalentes, test = "pp", type = "trend")
```

```
pp4 <- ndiffs(x = dados$ibc_br, test = "pp", type = "trend")
```

```
ordem_integracao_pp <- c(pp1, pp2, pp3, pp4)
```

```
ordem_integracao_pp
```

```
# Modelagem e Previsão fora da amostra -----
```

```
#Seleção de defasagens por critério de informação
```

```
lags_treino <- VARselect(y = dados_treino[-1], lag.max = 12, type = "both")$selection |>
```

```
max()
```

```
#Teste de Cointegração de Johansen pelo Máximo AutoValor
```

```
teste_cointegracao_treino <- ca.jo(
```

```
x = dados_treino [-1],
```

```
type = "eigen",
```

```
ecdet = "trend",
```

```
K = 2,
```

```
season = 12,
```

```
dumvar = dummies_treino[-1]
```

```
)
```

```
summary(teste_cointegracao_treino)
```

```
#Teste de Cointegração de Johansen pela estatística do Traço
```

```
teste_cointegracao_treino_trace <- ca.jo(
```

```
x = dados_treino [-1],
```

```
type = "trace",
```

```
ecdet = "trend",
```

```
K = 2,
```

```
season = 12,
```

```
dumvar = dummies_treino[-1]
```

```
)
```

```
summary(teste_cointegracao_treino_trace)
```

```
# Modelando um VAR -----
```

```
modelo_var_treino <- vec2var (teste_cointegracao_treino, r = 1)
```

```
# Testes de estabilidade -----
```

```
# Teste de autocorrelação (H0: ausência de correlação serial)
```

```
vars::serial.test(modelo_var_treino)
```

```
# Teste de normalidade (H0: normalidade dos resíduos)
```

```
vars::normality.test(modelo_var_treino)
```

```
# Teste para heterocedasticidade (H0: ausência de heterocedasticidade condicional)
```

```
vars::arch.test(modelo_var_treino)
```

```
# Previsão fora da amostra -----
```

```
# Produz previsão
```

```
previsao_treino <- predict(
```

```
  modelo_var_treino,
```

```
  n.ahead = nrow(dados_teste),
```

```
  dumvar = dummies_teste
```

```
)
```

```
# Dados para cálculo
```

```
observado <- dados_teste$seixos_equivalentes
```

```
previsto <- previsao_treino$fcst$seixos_equivalentes[, "fcst"]
```

```
erro <- observado - previsto
```

```
tabela_teste <- data.frame(
```

```
  Observado = observado,
```

```
  Previsto = previsto,
```

```
  Erro = erro
```

```
)
```

```
tabela_teste |>
```

```

mutate(Date = dados_teste$date) |>

pivot_longer(cols = c(Observado, Previsto),

names_to = "Tipo",

values_to = "Valor") |>

ggplot(aes(x = Date, y = Valor, color = Tipo)) +

geom_line() +

labs(title = "Dados Observados vs. Previsto",

x = "Data",

y = "Valores") +

theme_minimal() +

scale_color_manual(values = c("Observado" = "blue", "Previsto" = "red"))

# Métrica RMSE (Erro quadrático médio)

sqrt(mean(erro^2, na.rm = TRUE))

# Modelagem e previsão (cenário contrafactual) -----

# Seleção de defasagens VAR por critérios de informação

lags_ic <- VARselect(y = dados_pre_covid[-1], lag.max = 12, type = "both")$selection |>

max()

lags_ic

# Teste de Cointegração de Johansen pelo Máximo AutoValor

## Exemplo: K a ser definido por Concessionária de acordo com o resultado dos testes de estabilidade dos resíduos

teste_cointegracao <- ca.jo(

x = dados_pre_covid[-1],

type = "eigen",

K = 2,

ecdet = "trend",

```

```

season = 12,

dumvar = dummies_pre_covid[-1]

)

summary(teste_cointegracao)


#Teste de Cointegração de Johansen pela estatística do Traço

## Exemplo: K a ser definido por Concessionária de acordo com o resultado dos testes de estabilidade dos resíduos


teste_cointegracao_trace <- ca.jo(

x = dados_pre_covid[-1],

type = "trace",

K = 2,

ecdet = "trend",

season = 12,

dumvar = dummies_pre_covid[-1]

)

summary(teste_cointegracao_trace)


# Modelando o VAR em nível

modelo_var <- vars::vec2var(teste_cointegracao, r = 1)


# Teste de autocorrelação (H0: ausência de correlação serial)

serial.test(modelo_var)


# Teste de normalidade (H0: normalidade dos resíduos)

normality.test(modelo_var)

```

```
# Teste para heterocedasticidade (H0: ausência de heterocedasticidade condicional)
```

```
arch.test(modelo_var)
```

```
# Forecast - Cenário Contrafactual -----
```

```
# Produz previsão
```

```
previsao_contrafactual <- predict(  
  modelo_var,  
  n.ahead = nrow(dados_contrafactual),  
  dumvar = dummies_contrafactual  
)
```

```
# Tabela de previsão
```

```
tabela_contrafactual <- previsao_contrafactual$fcst$eixos_equivalentes |>  
  dplyr::as_tibble() |>  
  dplyr::mutate(date = max(dados_pre_covid$date) + 1:46)
```

```
# Visualização de dados
```

```
dados_pre_covid |>  
  dplyr::bind_rows(  
    tabela_contrafactual |> dplyr::rename("eixos_equivalentes" = "fcst")  
  ) |>  
  ggplot2::ggplot() +  
  ggplot2::aes(x = as.Date(date), y = eixos_equivalentes, ymin = lower, ymax = upper) +  
  ggplot2::geom_line() +  
  ggplot2::geom_vline(  
    xintercept = as.Date(max(dados_pre_covid$date) + 1),  
    linetype = "dashed"  
  ) +  
  ggplot2::geom_ribbon(alpha = 0.2, fill = "blue") +
```

```

ggplot2::scale_x_date(date_breaks = "2 years", date_labels = "%Y") +

ggplot2::labs(

title = "Previsão do Tráfego - LXX",

subtitle = "Projeções baseadas em um Modelo VAR/VECM",

y = "Eixos Equivalentes",

x = NULL,

caption = "Dados: ARTESP | Elaboração: ARTESP-DCE"

)

```

Tratamento final e exportando dados -----

#gerando tabela

tabela_resultado <-

dados |>

filter(date >= as.Date("2020-03-01")) |>

dplyr::select(

date, eixos_equivalentes) |>

rename(

observado = "eixos_equivalentes"

) |>

mutate (ic_inferior = tabela_contrafactual\$lower,

ic_superior = tabela_contrafactual\$upper,

projecao_central = tabela_contrafactual\$fcst,

variacao_extraordinaria = ifelse(

observado < ic_inferior, observado - ic_inferior, 0

)

)

#gerando gráfico

ggplot(data = tabela_resultado, aes(x = date)) +

```

geom_line(aes(y = observado, color = "Observado"), linetype = "dotted", size = 1, na.rm = TRUE) + # Dados observados em
pontilhada

geom_line(aes(y = ic_inferior, color = "IC Inferior"), size = 1, na.rm = TRUE) + # IC Inferior

geom_line(aes(y = ic_superior, color = "IC Superior"), size = 1, na.rm = TRUE) + # IC Superior

labs(title = "Dados Observados e Intervalos de Confiança",

x = "Data",

y = "Eixos_Equivalentes") + # Rótulo do eixo y

scale_color_manual(values = c("Observado" = "red", "IC Inferior" = "grey", "IC Superior" = "grey")) + # Definição de cores

theme_minimal() + # Tema minimalista

theme(legend.position = "bottom", # Posição da legenda na parte inferior

legend.title = element_blank(), # Remove o título da legenda

legend.background = element_rect(fill = "transparent"), # Fundo da legenda transparente

legend.key = element_blank()) + # Remove o fundo das chaves da legenda

annotate("text", x = Inf, y = -Inf, label = "ARTESP - SRE",

hjust = 1, vjust = 2, size = 3.5, color = "black", fontface = "italic") # Adiciona a fonte abaixo da legenda

#exportando para o excel

tabela_resultado <- tabela_resultado |>

mutate (

date = as.Date(date))

write_xlsx(tabela_resultado, "LXX_projecao_var.xlsx")

```

[1] Modelos Autoregressivos Integrados de Médias Móveis - *AutoRegressive Integrated Moving Average*, conforme Hyndman e Athanasopoulos (2018).

[2] *Vector Autoregressive Models*.

[3] Dados extraídos do Relatório do Movimento Mensal de Tráfego e Arrecadação (RMMTA) reportados periodicamente pelas Concessionárias à ARTESP.

[4] Série de número 24364 do Gerenciador de Séries Temporais do Banco Central do Brasil.

[5] Instituto Brasileiro de Geografia e Estatística

- [6] Técnica de decomposição de uma série temporal em tendência, sazonalidade e resíduos por meio da ferramenta denominada X13-ARIMA.
- [7] A esse respeito, segundo Hyndman e Athanassopoulos (2018): “A stationary time series is one whose properties do not depend on the time at which the series is observed.¹⁷ Thus, time series with trends, or with seasonality, are not stationary — the trend and seasonality will affect the value of the time series at different times. On the other hand, a white noise series is stationary — it does not matter when you observe it, it should look much the same at any point in time”.
- [8] Para maiores detalhes, consulte Wooldridge (2016, p. 715-717).
- [9] A cointegração procura verificar se duas ou mais variáveis possuem a mesma trajetória no longo prazo.
- [10] A função VARselect do pacote vars do *software R* calcula o número de defasagens com base nos critérios AIC (*Akaike Information Criterion*), HQ (*Hannan-Quinn Information Criterion*), SC (*Schwarz Bayesian Criterion*) e FPE (*Final Prediction Error*). Caso haja contradição entre os critérios, sugere-se realizar a estimação do modelo com todas as defasagens até o limite de 12.
- [11] A função ca.jo do pacote urca do *software R* realiza o teste de cointegração de *Johansen*.
- [12] Sugere-se a utilização da função vec2var do pacote vars do *software R*.
- [13] Para realização dos referidos testes, sugere-se a utilização das funções *serial.test*, *normality.test* e *arch.test* do pacote *tseries* do *software R*.
- [14] Para maiores informações, consulte o site: [Site ABCR](#)



Documento assinado eletronicamente por **André Isper Rodrigues Barnabé, Diretor Presidente**, em 22/05/2025, às 18:27, conforme horário oficial de Brasília, com fundamento no [Decreto Estadual nº 67.641, de 10 de abril de 2023](#).



A autenticidade deste documento pode ser conferida no site https://sei.sp.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0068049432** e o código CRC **35FE10FD**.