



University of
Texas Libraries



e-revist@s



Centro Unversitário Santo Agostinho

revistafsa

www4.fsnet.com.br/revista

Rev. FSA, Teresina, v. 20, n. 9, art. 7, p. 139-164, set. 2023

ISSN Impresso: 1806-6356 ISSN Eletrônico: 2317-2983

<http://dx.doi.org/10.12819/2023.20.9.7>

DOAJ DIRECTORY OF
OPEN ACCESS
JOURNALS

WZB
Wissenschaftszentrum Berlin
für Sozialforschung



Impacto da Covid-19 Sobre as Movimentações dos Aeroportos Brasileiros

Impact of Covid-19 on Movements at Brazilian Airports

Rodolfo Benedito Zattar da Silva

Doutor em Engenharia de Produção pela Universidade Federal do Rio Grande do Sul
Professor da Universidade Federal de Mato Grosso
Email: rodolfo.silva@ufmt.br

Cinthia Serenotti Brigante

Mestre em Engenharia de Produção pela Universidade Federal de São Carlos
Professora da Universidade Federal de Mato Grosso
Email: cinthia.brigante@gmail.com

Cristiano Oliveira Nicolau

Graduando em Engenharia de Transportes pela Universidade Federal de Mato Grosso
Email: crist.nic7@gmail.com

Fábia Fernanda da Costa Aires

Mestre em Ciências Ambientais pela Universidade de Cuiabá
Email: fabia_aires@hotmail.com

Endereço: Rodolfo Benedito Zattar da Silva

Av. Fernando Corrêa da costa, nº 2.367, Bairro Boa Esperança, CEP: 78060-900, Cuiabá/MT, Brasil.

Endereço: Cinthia Serenotti Brigante

Av. Fernando Corrêa da costa, nº 2.367, Bairro Boa Esperança, CEP: 78060-900, Cuiabá/MT, Brasil.

Endereço: Cristiano Oliveira Nicolau

Av. Fernando Corrêa da costa, nº 2.367, Bairro Boa Esperança, CEP: 78060-900, Cuiabá/MT, Brasil.

Endereço: Fábia Fernanda da Costa Aires

Av. Fernando Corrêa da costa, nº 2.367, Bairro Boa Esperança, CEP: 78060-900, Cuiabá/MT, Brasil.

Editor-Chefe: Dr. Tonny Kerley de Alencar Rodrigues

Artigo recebido em 02/06/2023. Última versão recebida em 05/07/2023. Aprovado em 06/07/2023.

Avaliado pelo sistema Triple Review: a) Desk Review pelo Editor-Chefe; e b) Double Blind Review (avaliação cega por dois avaliadores da área).

Revisão: Gramatical, Normativa e de Formatação



RESUMO

O setor da aviação civil brasileira sofreu impactos significativos nas suas atividades em decorrência da pandemia da COVID-19. Desse modo, o presente trabalho teve como objetivo avaliar o impacto do primeiro ano da pandemia sobre a movimentação de cargas e passageiros nos aeroportos brasileiros. Para isto, foram coletados dados históricos (séries temporais) das movimentações de cargas e passageiros do sistema Hórus da Secretaria Nacional de Aviação Civil, compreendendo o período de janeiro de 2004 a fevereiro de 2020. Em seguida, foram obtidas as estatísticas descritivas e identificados os padrões das duas séries. Logo após, foram avaliados os desempenhos de cinco modelos de previsão (dois individuais e três de combinação) para obtenção de valores futuros das séries temporais de março de 2020 a fevereiro de 2021. Foi possível observar que o modelo de Holt-Winters Aditivo foi o mais preciso para prever a movimentação futura de cargas. Além disso, pôde-se verificar que o modelo SARIMA(0,1,1)(0,1,1)₁₂ foi o mais recomendado para prever a movimentação futura de passageiros nos aeroportos brasileiros. Por fim, constatou-se que o volume observado de movimentação de cargas foi 28,55% inferior ao volume previsto pelo modelo de Holt-Winters Aditivo para o período de março de 2020 a fevereiro de 2021). Já o volume observado de movimentação de passageiros foi 63,41% inferior ao volume previsto pelo modelo SARIMA(0,1,1)(0,1,1)₁₂ para o mesmo período.

Palavras-chave: Aeroportos. Movimentação. COVID-19. Previsões. Séries temporais.

ABSTRACT

The Brazilian civil aviation sector suffered significant impacts on its activities as a result of the COVID-19 pandemic. Thus, the present work aimed to evaluate the impact of the first year of the pandemic on the movement of cargo and passengers at Brazilian airports. For this, historical data (time series) of cargo and passenger movements of the Horus system of the National Civil Aviation Secretariat were collected, covering the period from January 2004 to February 2020. Then, descriptive statistics were obtained and the patterns of the two series. Afterwards, the performances of five forecast models (two individual and three combination) were evaluated to obtain future values of the time series from March 2020 to February 2021. It was possible to observe that the Additive Holt-Winters model was the best model. more accurate for predicting future cargo movement. In addition, it was possible to verify that the SARIMA (0,1,1)(0,1,1)₁₂ model was the most recommended for predicting the future movement of passengers at Brazilian airports. Finally, it was found that the observed volume of cargo handling was 28.55% lower than the volume predicted by the Additive Holt-Winters model for the period from March 2020 to February 2021). The observed volume of passenger movement was 63.41% lower than the volume predicted by the SARIMA (0,1,1)(0,1,1)₁₂ model for the same period.

Keywords: Airports. Movement. COVID-19. Forecasts. Time series.

1 INTRODUÇÃO

O transporte aéreo é um modo de transporte muito utilizado mundialmente para movimentação de cargas e passageiros. No Brasil, este modo apresentou uma evolução considerável ao longo dos anos, principalmente, devido à grande demanda interna e desregulamentação do setor que proporcionou uma maior concorrência interna e a entrada de mais companhias ofertando serviços (FERREIRA *et al.*, 2020).

No ano de 2020, o mundo inteiro foi surpreendido por um período de intensa turbulência devido à pandemia gerada pela COVID-19. Em decorrência do número crescente de casos da doença e da rápida proliferação do vírus pelos países, as autoridades mundiais começaram a adotar medidas de restrição de circulação das pessoas (COSTA *et al.*, 2020).

Assim, a pandemia causou inicialmente o fechamento dos aeroportos e das fronteiras como uma forma de conter a rápida dispersão do vírus, uma vez que as aeronaves são ambientes fechados nos quais muitas pessoas ficam confinadas por um longo período (SUN *et al.*, 2020). Assim, observou-se a necessidade de reestruturar os terminais e alterar os protocolos de segurança para o retorno das atividades (CHOI; 2021). Apesar disso, foi possível observar que houve uma redução significativa na quantidade de voos em todo o mundo, principalmente no ano de 2020 (HOTLE; MUMBOWER, 2021).

As restrições impostas pela pandemia fizeram com que a grande maioria dos setores econômicos fossem afetados de diversas maneiras, tanto positiva quanto negativamente (COSTA *et al.*, 2020). Os impactos ocasionados pela pandemia ainda não podem ser completamente mensurados, mas podem ser notados de forma considerável na saúde, comércio, economia, sociedade, serviços e, conseqüentemente, para os empreendedores e seus empreendimentos (NASSIF *et al.*, 2020).

No caso da aviação civil brasileira, a análise dos impactos da pandemia sobre a movimentação de cargas e passageiros pode ser realizada comparando os valores futuros previstos dessas duas séries temporais (que seria um cenário sem pandemia) com os valores observados durante o período de pandemia. Desse modo, os padrões observados dos valores passados para as duas séries temporais (movimentação de cargas e passageiros) até o mês de fevereiro de 2020, que foi o mês que antecedeu o mês de grande restrição da circulação das pessoas por conta da COVID-19, podem ser usados para realizar previsões futuras das movimentações e compará-las com os valores

observados durante o primeiro ano de pandemia (março de 2020 a fevereiro de 2021), que foi o procedimento adotado no presente trabalho.

As pesquisas realizadas para avaliar os impactos da pandemia sobre as movimentações de cargas e passageiros nos aeroportos brasileiros ainda são incipientes (SENNA; SILVA, 2021; SILVA *et al.* 2021), o que justifica a realização de novos estudos nesta área. No trabalho de Senna e Silva (2021) foram realizadas previsões para o ano de 2020 das séries temporais de passageiros e cargas transportadas pela aviação civil brasileira utilizando apenas os procedimentos e modelos da metodologia de Box e Jenkins (1976). Em seguida, os autores realizaram comparações com os valores previstos e realizados para determinar o impacto da pandemia sobre essas duas variáveis.

Já no estudo de Silva *et al.* (2021), foram avaliados os desempenhos de cinco modelos de previsão (dois individuais e três de combinação) para obtenção de valores futuros da série de movimentação de passageiros do Aeroporto Internacional de Várzea Grande-MT, considerando o período de março a dezembro de 2020. O modelo de combinação de previsões por regressão linear foi o que apresentou os menores erros de previsão e foi escolhido para obtenção de valores futuros da série estudada. Na comparação entre os valores previstos e observados, os autores constataram que a movimentação registrada de passageiros foi 58,16% menor que a prevista para o período. Neste artigo, utilizou-se uma abordagem semelhante à do estudo de Silva *et al.* (2021), que é mais completa, ou seja, foi analisada uma quantidade maior de modelos de previsão quando comparado com o trabalho de Senna e Silva (2021). Isto se configura como um esforço maior para obter previsões mais acuradas e confiáveis para as séries temporais estudadas.

Diante do exposto, o presente trabalho teve como objetivo analisar o impacto do primeiro ano da pandemia da COVID-19 sobre a movimentação de cargas e passageiros nos aeroportos brasileiros, considerando modelos individuais e de combinação de previsões.

2 REFERENCIAL TEÓRICO

2.1 Séries temporais

De acordo com Bayer e Souza (2010), as previsões de séries temporais são obtidas partindo do pressuposto básico de que o padrão ocorrido no passado se repetirá

no futuro. Isto porque a análise de série temporal tem como objetivo identificar relações de dependência existentes de forma temporal no conjunto de dados e identificar o mecanismo gerador da série para capturar periodicidades relevantes nos valores observados, descrever seu comportamento e realizar previsões.

Em geral, as séries temporais podem apresentar os seguintes padrões (LEVINE, *et al.* 2016):

- (i) tendência – padrão de movimento gradual necessariamente de longo prazo que direciona os dados de forma crescente ou decrescente ao longo do tempo;
- (ii) sazonalidade – corresponde a flutuações regulares de curto prazo que se repetem em intervalos relativamente constantes de tempo. Logo, a existência da sazonalidade em uma série temporal somente pode ocorrer porque ela é influenciada por algum fator sazonal;
- (iii) ciclicidade – corresponde a variações ondulatórias de longo prazo que ocorrem em períodos irregulares;
- (iv) irregularidade – vista como as alterações na série temporal que ocorrem devido a eventos excepcionais que, na maioria das vezes, não podem ser presumidos e, portanto, incluídos nos modelos.

As variáveis relacionadas ao setor de transporte aéreo, na maioria das vezes, apresentam padrão sazonal, conforme pôde ser observado nos trabalhos de Senna e Silva (2021) e Silva *et al.* (2021). Assim, há necessidade de se considerar modelos de previsão que levam em consideração esse padrão temporal para as séries temporais aqui estudadas.

Para fins deste estudo, os modelos foram classificados em: (i) modelos de previsões individuais que consideram a sazonalidade - Holt-Winters (Aditivo e Multiplicativo) e SARIMA $(p,d,q)(P,D,Q)_s$; e (ii) modelos de previsões combinadas - variância mínima, média aritmética e regressão linear. As definições e expressões matemáticas dessas duas classes de modelos de previsões são apresentadas a seguir.

2.2 Modelos de previsões individuais

2.2.1 Modelos de Holt-Winters

Os modelos de Holt-Winters são apropriados para séries temporais que apresentam padrões de tendência e sazonalidade. Assim, eles usam quatro expressões

matemáticas para estimar o nível, tendência e sazonalidade da série temporal estudada e leva em consideração três constantes de suavização (α , β e γ) (HYNDMAN e ATHANASOPOULOS, 2014). Dependendo do comportamento da componente sazonal da série temporal, o modelo de Holt-Winters pode ser aditivo ou multiplicativo. O primeiro é usado para séries temporais cuja amplitudes (diferenças entre os maiores e menores valores) da sazonalidade não variam com os seus níveis. Já o modelo multiplicativo é apropriado para séries temporais quando a amplitude sazonal sofre variações com os seus níveis (HOLT, 2004).

As expressões matemáticas de (1) – (4), são utilizadas para realizar previsões para o modelo multiplicativo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998):

$$F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (1)$$

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (4)$$

Onde: F_{t+m} é a previsão para período $t + m$ (horizonte de previsão), L_t é o nível da série temporal, b_t é a estimativa da tendência, S_t é o componente sazonal, m são os períodos a frente que se deseja obter previsões, $m = 1, 2, 3, \dots$, Y_t é o valor observado no período t , s é o período de sazonalidade, α , β e γ são constantes de suavização, com valores entre 0 e 1.

Já as previsões pelo modelo aditivo podem ser obtidas pelas expressões matemáticas de (5) a (8) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998):

$$F_{t+m} = (L_t + b_t m) + S_{t-s+m} \quad (5)$$

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (6)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (7)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (8)$$

Em que: F_{t+m} , L_t , b_t , S_t , m , Y_t , s , α , β e γ já foram definidos anteriormente.

2.2.2 Modelo SARIMA

O modelo Autorregressivo Integrado e de Média Móvel Sazonal, do inglês *Seasonal Autoregressive Integrated Moving Average* (SARIMA), também é apropriado para ser usado para modelagem e previsão de valores futuros de séries temporais que apresentam comportamento sazonal. Tal modelo apresenta a seguinte notação: SARIMA (p,d,q)(P,D,Q)_s, sendo que (p,d,q) corresponde à parte não sazonal, (P,D,Q) representa a parte sazonal e *s* é o número de períodos da sazonalidade (HYNDMAN e ATHANASOPOULOS, 2014).

Logo, um modelo genérico SARIMA é representado pela seguinte expressão matemática (9):

$$(1 - \phi_1 L - \dots - \phi_p L^p)(1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps})(1 - L)^d \quad (9)$$

$$(1 - L^s)^D y_t = (1 - \vartheta_1 L - \dots - \vartheta_q L^q)(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs}) \varepsilon_t$$

Sendo que: *L* é o operador de defasagem ($Ly_t = y_{t-1}$ ou $L^s y_t = y_{t-s}$), $(1 - \phi_1 L - \dots - \phi_p L^p)$ é a parte autoregressiva não-sazonal de ordem *p*, $(1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps})$ é a parte autoregressiva sazonal de ordem *P* e período sazonal *s*, $(1 - L)^d$ é parte de integração não-sazonal de ordem *d*, $(1 - L^s)^D$ é parte de integração sazonal de ordem *D* e período sazonal *s*, $(1 - \theta_1 L - \dots - \theta_q L^q)$ é a parte não-sazonal de médias móveis de ordem *q* e $(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs})$ é a parte sazonal de médias móveis de ordem *Q* e período sazonal *s*.

2.3 Modelos de previsões combinadas

A combinação de duas ou mais técnicas de previsões individuais tem sido bem aceita na literatura e no campo empresarial por apresentar evidências de que as acurácias das previsões são melhoradas (COSTANTINI; PAPPALARDO, 2010; WEBBY; O'CONNOR, 1996). Segundo Lawrence *et al.* (2006), a melhoria na acurácia se deve ao fato de que quando se realiza a combinação das previsões são levadas em conta informações capturadas de diversas fontes, aumentando as informações sob as quais as previsões estão fundamentadas.

Na literatura, são apresentados diversos modelos que podem ser utilizados para obtenção de previsões combinadas, sendo que os mais comumente usados são o de

variância mínima, média aritmética e regressão linear. As definições e expressões matemáticas desses três modelos de combinação são apresentadas a seguir.

2.3.1 Combinação de previsões por variância mínima

A combinação de previsões individuais originou-se a partir do estudo seminal realizado por Bates e Granger (1969), quando foi apresentado o modelo denominado de método da variância mínima. Os autores propuseram realizar a combinação de previsões por meio de uma combinação linear de duas previsões individuais objetivas não viciadas (ou devidamente corrigidas), com a atribuição de um peso (w) para a previsão individual obtida pelo primeiro modelo e um peso $1 - w$ para a previsão do segundo. Assim, um peso maior w é atribuído ao modelo que apresentar os menores erros de previsão. A previsão combinada pelo método da variância mínima pode ser obtida através da expressão (10):

$$C = w f_1 + (1 - w) f_2 \quad (10)$$

Onde: C é o valor da previsão combinada, f_1 é a previsão do modelo 1, f_2 é a previsão do modelo 2, w é o peso da previsão 1.

O peso w é determinado de duas formas distintas, dependendo do comportamento dos erros das previsões individuais, ou seja, se os erros são ou não correlacionados (BATES; GRANGER, 1969). Para os casos em que os erros dessas previsões individuais são correlacionados, o peso w é determinado pela expressão (11):

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \quad (11)$$

Sendo que: ρ é o valor da correlação linear entre os erros das previsões obtidas em f_1 e f_2 , σ_1^2 e σ_2^2 correspondem à variância dos erros de previsão de f_1 e f_2 , respectivamente.

Em situações em que os erros das previsões individuais não são correlacionados ($\rho = 0$), o peso (w) é obtido conforme apresentado na expressão (12):

$$w = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (12)$$

Em que: σ_1^2 e σ_2^2 já foram definidos anteriormente.

2.3.2 Combinação de previsões por média aritmética

Após o estudo seminal de Bates e Granger (1969), diversos outros modelos de combinação foram apresentados na literatura. A combinação de duas previsões individuais através da média aritmética tem sido uma das mais utilizadas. Neste modelo, um peso igual a 0,50 é atribuído a cada uma das previsões individuais obtidas (DE GOOIJER e HYNDMAN, 2006). A combinação através da média aritmética, com duas previsões individuais, é obtida a partir da expressão (13):

$$C = 0,5 f_1 + 0,5 f_2 \quad (13)$$

Onde: C é o valor da previsão combinada, f_1 é a previsão do modelo 1 e f_2 é a previsão do modelo 2.

2.3.3 Combinação de previsões por regressão linear

Neste modelo é realizada a combinação de modelos de previsões individuais fazendo-se o uso de uma forma estruturada de regressão, de modo que a previsão combinada é a variável resposta e as previsões individuais são as variáveis explicativas (GRANGER e RAMANATHAN, 1984).

Desse modo, a combinação através do método de regressão linear é realizada a partir da expressão (14):

$$C = \alpha + k_1 f_1 + k_2 f_2 \quad (14)$$

Em que: C é o valor da previsão combinada, α é o intercepto vertical da regressão, k_1 e k_2 são os coeficientes de regressão obtidos para as previsões dos modelos 1 e 2, respectivamente, f_1 é a previsão do modelo 1 e f_2 é a previsão do modelo 2.

Ressalta-as que os valores do intercepto vertical (α) e dos coeficientes de regressão dos modelos 1 e 2 (k_1 e k_2) são obtidos considerando os valores observados (y_t) da série temporal como variável resposta (dentro da amostra). Após obter essas constantes, são então obtidas as previsões combinadas futuras (ou seja, para fora da amostra) a partir da expressão (14).

3 METODOLOGIA

Para realização do presente trabalho, foram consideradas duas séries históricas (séries temporais), sendo elas: (i) movimentação de cargas (toneladas); e, (ii) movimentação de passageiros (mil). Para ambas, foram considerados os voos domésticos e internacionais, embarque e desembarque, regular e não regular, aeródromos das capitais e regionais. Foram consideradas as séries temporais mensais, compreendendo o período de janeiro de 2004 a fevereiro de 2020, que foi o mês que antecedeu o início da pandemia da Covid-19 no Brasil. Ao todo, foram obtidas 194 observações para cada série temporal analisada.

Os dados foram obtidos a partir da base de dados Hórus que é um sistema da Secretaria Nacional de Aviação Civil. A plataforma apresenta informações sobre a aviação civil brasileira e pode ser acessada através do seguinte endereço eletrônico: <<https://horus.labtrans.ufsc.br/gerencial/?auth=s#Movimentacao/Evolucao>>.

Todos os dados foram obtidos em planilhas eletrônicas e analisados no software R. Na sequência, os dados foram plotados para identificação dos padrões das duas séries temporais analisadas, a partir de uma análise gráfica visual. Em seguida, foram obtidas as estatísticas descritivas das duas séries temporais.

Para realizar o processo de modelagem das séries temporais, a base de dados original com 194 observações foi dividida em duas porções, sendo a primeira para treinamentos e a segunda para testes dos modelos. Logo, a porção de dados de treinamento (182 primeiras observações) foi utilizada para a estimação dos parâmetros dos modelos. Já a porção de dados de teste (12 últimas observações) foi usada para validação e análise dos seus desempenhos.

As previsões individuais para as duas séries temporais estudadas foram obtidas pelos modelos de Holt-Winters no seu formato Aditivo e Multiplicativo. Os desempenhos desses dois modelos foram comparados através do Erro Absoluto Médio ou *Mean Absolute Error* (MAE), Erro Quadrático Médio ou *Mean Square Error* (MSE)

e do Erro Percentual Absoluto Médio ou *Mean Absolute Percentage Error* (MAPE), sendo escolhido para compor a previsão combinada aquele que apresentou o melhor desempenho na porção de dados de teste, ou seja, menores valores de MAE, MSE e MAPE. As definições e expressões matemáticas do MAE, MSE e MAPE podem ser encontradas em Makridakis *et al.* (1998).

Logo em seguida, foram obtidas as previsões individuais pelos modelos SARIMA da classe de modelos de Box e Jenkins (1976). Para isto, foi utilizado um algoritmo desenvolvido por Hyndman e Khandakar (2008) para seleção automática de modelos ARIMA. Tal algoritmo está implementado no pacote *forecast* (função *auto.arima*) do software R. Posteriormente, foram realizadas análises dos resíduos do modelo selecionado para verificar se eles apresentaram comportamento de ruído branco, isto é, se a média de seus componentes é zero e a variância constante e, ainda, se eles não são autocorrelacionados. Tal procedimento foi realizado com a aplicação do teste de Ljung-Box. Além disso, foram estimados os critérios de informações *Akaike's Information Criteria* (AIC) e *Bayesian Information Criteria* (BIC) com o intuito de mensurar o ajuste do modelo escolhido. Maiores detalhes relacionados às análises dos resíduos e dos critérios de informação AIC e BIC, respectivamente, podem ser consultados em Morettin (2011).


Com a obtenção das previsões individuais, foram então obtidas as previsões combinadas através dos modelos de variância mínima, média aritmética e regressão linear. Os desempenhos desses três modelos foram mensurados e, novamente, foram analisados os desempenhos dos cinco modelos de previsão (dois individuais e três de combinação) através das medidas de acurácia MAE, MSE e MAPE. O procedimento foi realizado com o intuito de escolher o modelo para se obter previsões fora da amostra, ou seja, para o período de março de 2020 a fevereiro de 2021.

Por fim, os valores previstos pelos modelos selecionados para as duas séries temporais foram comparados com os valores observados para mensurar o impacto sobre a movimentação de cargas e passageiros nos aeroportos brasileiros durante o primeiro ano da pandemia da Covid-19.

4 RESULTADOS E DISCUSSÃO

A Figura 1 apresenta a série temporal da movimentação de cargas (ton) nos aeroportos brasileiros para o período de janeiro de 2004 a fevereiro de 2020.

Figura 1 - Série temporal da movimentação de cargas (ton) nos aeroportos brasileiros



A Tabela 1 apresenta as estatísticas descritivas para a série temporal da Figura 1, onde pode-se observar que a movimentação média de todo o período analisado foi de 110.412 toneladas. O menor volume de movimentação de cargas (63.095 toneladas) foi observado no mês de fevereiro de 2009. Por outro lado, a maior movimentação (144.431 toneladas) foi registrada no mês de novembro de 2012.

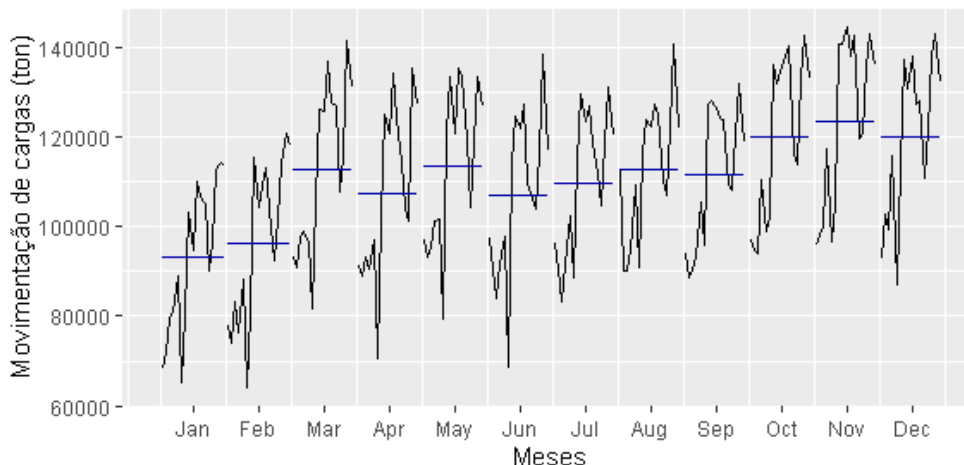
Tabela 1 - Estatísticas descritivas da movimentação de cargas em toneladas

Estatísticas	Valores (ton)
Mínimo	63.095
1º Quartil	95.857
Mediana	111.346
Média	110.412
3º Quartil	125.956
Máximo	144.431

Com o intuito de verificar o comportamento da série temporal de movimentação de cargas, foi realizada a análise visual do gráfico que demonstra os comportamentos e os valores médios (barras azuis) da movimentação de cargas (ton) para cada mês durante todo o período analisado, conforme apresentado na Figura 2. Assim, pode-se observar

que a série temporal apresenta um componente sazonal com picos na movimentação de cargas em novembro de cada ano (Figura 2).

Figura 2 - Comportamentos e valores médios mensais da movimentação de cargas (ton) nos aeroportos brasileiros



Após a identificação do elemento sazonal na Figura 2, pôde-se observar através da função *frequency* do pacote *forecast* do R, que o ciclo sazonal (*s*) da série temporal de movimentação de cargas é de 12 meses ($s = 12$), isto é, picos de movimentação em novembro de cada ano.

A Tabela 2 apresenta os parâmetros estimados e as medidas de acurácia para a porção de dados de teste para os modelos de Holt-Winters Aditivo e Multiplicativo, respectivamente. É possível verificar que o modelo que apresentou o melhor desempenho, isto é, menores valores (erros de previsão) para as medidas de acurácia MAE, MSE e MAPE, respectivamente, foi o de Holt-Winters Aditivo. Tal modelo foi então selecionado para obtenção das previsões combinadas juntamente com o modelo SARIMA.

Tabela 2 - Parâmetros dos modelos de Holt-Winters e medidas de acurácia para a série de movimentação de cargas na porção de dados de teste (12 últimas observações)

Modelos	Parâmetros	MAE	MSE	MAPE
Holt-Winters Aditivo	$\alpha = 0,717$ $\beta = 0,000$ $\gamma = 0,000$	3.458,64	18.539.225,80	2,81
Holt-Winters Multiplicativo	$\alpha = 0,590$ $\beta = 0,000$ $\gamma = 0,223$	4.181,12	27.922.052,44	3,44

A Figura 3 apresenta os valores observados da série temporal de movimentação de cargas, valores ajustados que foram previstos pelos modelos de Holt-Winters e valores previstos pelos dois modelos para os 12 períodos fora da amostra (março de 2020 a fevereiro de 2021).

Figura 3 - Série temporal observada de movimentação de cargas, valores ajustados aos dados observados e valores previstos para fora da amostra pelos dois modelos de Holt-Winters



Em seguida, foram obtidas as previsões pelo modelo SARIMA $(p,d,q)(P,D,Q)_s$, sendo que o modelo estimado automaticamente pelo software R foi o SARIMA(2,0,2)(1,1,0)₁₂. Desse modo, pode-se verificar que houve a necessidade de realizar uma diferenciação sazonal indicada pelo segundo termo ($D = 1$) da parcela sazonal do modelo. Tal procedimento é uma premissa básica dos modelos SARIMA para transformar séries temporais não estacionárias (como a observada neste estudo) em séries estacionárias. A Tabela 3 apresenta os parâmetros estimados para o modelo SARIMA(2,0,2)(1,1,0)₁₂, bem como os critérios AIC e BIC e as medidas de acurácia (MAE, MSE e MAPE) obtidas para este modelo na porção de dados de teste.


Tabela 3 - Parâmetros do modelo SARIMA(2,0,2)(1,1,0)₁₂ e medidas de acurácia para a série de movimentação de cargas na porção de dados de teste (12 últimas observações)

Modelo	Parâmetros	Erro padrão	AI C	BI C	M AE	MSE	MAPE
SARIMA(2,0,2)(1,1,0) ₁₂	$\phi_1 =$	0,					
	0,756	36					
	0	57					
	$\phi_2 =$	0,					
	0,140	33					
	7	92					
	$\Phi_1 =$	0,					
	-	36	3.7	3.7	4.5	34.018	
	0,075	23	22,	44,	33,	.897,5	3,
	9		03	46	00	9	68
$\Phi_2 =$	0,						
0,102	11						
2	16						
$\theta_1 =$	0,						
0,445	06						
4	83						

O teste de Ljung-Box retornou um p-valor igual a 0,747, o que indica que os resíduos do modelo SARIMA(2,0,2)(1,1,0)₁₂ não são correlacionados. Portanto, o mesmo pode ser utilizado para prever a movimentação de cargas nos aeroportos brasileiros.

Na Figura 4, são apresentados os valores observados da série temporal de movimentação de cargas, valores ajustados que foram previstos pelo modelo SARIMA (2,0,2)(1,1,0)₁₂ e valores previstos pelo mesmo modelo para os 12 períodos fora da amostra (março de 2020 a fevereiro de 2021). A área sombreada pela cor azul, para o período fora da amostra, delimita os intervalos de confiança de 95% para as previsões obtidas.

Figura 4 - Série temporal observada, valores ajustados aos dados e valores previstos para fora da amostra pelo modelo SARIMA (2,0,2)(1,1,0)₁₂



Com a obtenção das previsões individuais da série temporal de movimentação de cargas pelos modelos de Holt-Winters Aditivo e SARIMA (2,0,2)(1,1,0)₁₂, foram obtidas as previsões combinadas através dos modelos de variância mínima com erros não correlacionados, média aritmética e regressão linear. Logo em seguida, os desempenhos dos dois modelos de previsões individuais e dos três de combinação de previsões foram comparados considerando as medidas de acurácia MAE, MSE e MAPE, respectivamente, na porção de dados de teste. Os resultados das medidas de acurácia são apresentados na Tabela 4.

Tabela 4 - Medidas de acurácia dos modelos de previsões individuais e de combinação para a série de movimentação de cargas na porção de dados de teste (12 últimas observações)

Modelos	MAE	MSE	MAPE
Holt-Winters Aditivo	3.458,64	18.539.225,80	2,81
SARIMA(2,0,2)(1,1,0) ₁₂	4.533,00	34.018.897,59	3,68
Previsão combinada (Média Aritmética)	3.902,85	22.712.846,87	3,17
Previsão combinada (Variância Mínima)	3.806,50	21.612.848,00	3,09
Previsão combinada (Regressão Linear)	3.460,77	18.691.742,13	2,81

Na Tabela 4, pode-se verificar que os modelos Holt-Winters Aditivo e Previsão combinada por regressão linear apresentaram praticamente os mesmos desempenhos em termo das medidas de acurácia (MAE, MSE e MAPE). Entretanto, o modelo de Holt-Winters Aditivo foi selecionado para realizar previsões futuras da movimentação de cargas nos aeroportos brasileiros, considerando o critério de parcimônia (modelos mais simples devem ser selecionados em detrimento aos mais complexos).

A Tabela 5 apresenta os valores previstos para a série temporal de movimentação de cargas pelo modelo de Holt-Winters Aditivo (Coluna A), valores observados (Coluna B), diferença entre os valores observados e previstos, bem como a variação percentual entre os valores previstos e observados para o período fora da amostra (março de 2020 a fevereiro de 2021), ou seja, durante o primeiro ano da pandemia da Covid-19.


Tabela 5 - Valores previstos pelo modelo de Holt-Winters Aditivo, valores observados, diferença e variação percentual para a série de movimentação de carga para o período fora da amostra

Períodos	Valores previstos (Holt-Winters Aditivo) (A)	Valores Observados (B)	Diferença (B) – (A)	Varição Percentual [(B) – (A)]/(A)
Março/2020	135.199,61	110.672,57	-24.527,04	-0,1814
Abril/2020	129.697,78	53.533,63	-76.164,15	-0,5872
Maió/2020	135.557,34	63.794,13	-71.763,21	-0,5294
Junho/2020	128.385,30	67.874,29	-60.511,01	-0,4713
Julho/2020	131.509,31	80.587,09	-50.922,23	-0,3872
Agosto/2020	134.616,66	88.863,14	-45.753,52	-0,3399
Setembro/2020	133.891,69	96.379,55	-37.512,13	-0,2802
Outubro/2020	141.597,02	111.114,23	-30.482,80	-0,2153
Novembro/2020	145.088,44	118.557,59	-26.530,85	-0,1829
Dezembro/2020	141.531,57	122.148,00	-19.383,58	-0,1370
Janeiro/2021	115.692,98	122.045,34	6.352,36	0,0549
Fevereiro/2021	118.547,55	101.456,16	-17.091,39	-0,1442
Total			-	
	1.591.315,26	1.137.025,72	454.289,55	-0,2855

Pode-se verificar, na Tabela 5, que o mês de abril de 2020 foi o que sofreu o maior impacto, ou seja, maior redução (-58,72%) na movimentação de cargas, devido às restrições impostas para conter o avanço da COVID-19, seguido pelos meses de maio, junho, julho, agosto que sofreram reduções nos volumes observados (coluna B) acima de 30% quando comparados com os valores previstos (coluna A). O volume total previsto de movimentação de cargas durante o primeiro ano da pandemia foi 1.591.315,26 toneladas, enquanto o volume observado foi de 1.137.025,72 toneladas. Desse modo, é possível observar que o volume de cargas movimentadas foi 28,55% inferior ao volume previsto para o período considerado (março de 2020 a fevereiro de 2021).

Na Figura 5, é apresentada a série temporal da movimentação de passageiros (mil) nos aeroportos brasileiros para o período de janeiro de 2004 a fevereiro de 2020.

Figura 5 - Série temporal da movimentação de cargas (ton) nos aeroportos brasileiros



Na Tabela 6, são apresentadas as estatísticas descritivas para a série temporal de movimentação de passageiros apresentada na Figura 5. Pode-se verificar que a movimentação média de todo o período analisado foi de 13.761 mil passageiros. Já o menor volume de movimentação de passageiros (5.504 mil) foi observado no mês de fevereiro de 2004. Por outro lado, a maior movimentação (21.250 mil) foi registrada no mês de janeiro de 2020.

Tabela 6 - Estatísticas descritivas da movimentação de passageiros (mil)


Estatísticas	Valores (mil)
Mínimo	5.504
1º Quartil	9.240
Mediana	15.728
Média	13.761
3º Quartil	17.270
Máximo	21.250

A análise dos comportamentos e dos valores médios (barras azuis) da movimentação de passageiros (mil), para cada mês durante o período analisado, permitiu identificar que a série temporal apresenta um componente sazonal com picos na movimentação de passageiros em janeiro de cada ano (Figura 6), pois foi o mês com a maior média de movimentação.

Ainda na Figura 6, é possível verificar que o volume médio de passageiros sofre uma queda considerável de janeiro para fevereiro, se mantém praticamente estável nos meses de março, abril, maio e junho e aumento em julho. Logo após, o volume apresenta

uma queda brusca de julho para agosto e praticamente mantém o volume médio nos meses de setembro, outubro e novembro, voltando a aumentar no mês de dezembro. Foi possível identificar através da função *frequency* do pacote *forecast* do R já descrito anteriormente, que o ciclo sazonal (s) da série temporal é de 12 meses ($s = 12$), isto é, os picos do volume de movimentação de passageiros ocorrem sempre nos meses de janeiro de cada ano. Muito provavelmente, tal comportamento pode estar associado ao período de férias escolares, quando se observa uma maior movimentação de passageiros em viagens de férias nos aeroportos brasileiros.

Figura 6 - Comportamentos e valores médios mensais da movimentação de passageiros (mil) nos aeroportos brasileiros



Na Tabela 7, são apresentados os parâmetros estimados e as medidas de acurácia para a porção de dados de teste para os modelos de Holt-Winters Aditivo e Multiplicativo, respectivamente. Pode-se observar que assim como ocorreu para a série temporal de movimentação de cargas, que o modelo de Holt-Winters Aditivo foi o que apresentou o melhor desempenho, isto é, menores valores (erros de previsão) para as medidas de acurácia MAE, MSE e MAPE, respectivamente.

Tabela 7 - Parâmetros dos modelos de Holt-Winters e medidas de acurácia para a série de movimentação de passageiros na porção de dados de teste (12 últimas observações)

Modelos	Parâmetros	MAE	MSE	MAPE
Holt-Winters Aditivo	$\alpha = 0,399$	283,30	133.634,51	1,62
	$\beta = 0,000$			
	$\gamma = 0,524$			
Holt-Winters Multiplicativo	$\alpha = 0,783$	394,24	241.052,57	2,25
	$\beta = 0,000$			
	$\gamma = 0,214$			

Na Figura 7, são apresentados os valores observados da série temporal de movimentação de passageiros, valores ajustados que foram previstos pelos modelos de Holt-Winters e valores previstos pelos dois modelos para os 12 períodos fora da amostra (março de 2020 a fevereiro de 2021).

Figura 7 - Série temporal observada de movimentação de passageiros, valores ajustados aos dados observados e valores previstos para fora da amostra pelos dois modelos de Holt-Winters



O modelo SARIMA $(p,d,q)(P,D,Q)_s$ estimado automaticamente pelo software R para série temporal de movimentação de passageiros foi o SARIMA(0,1,1)(0,1,1)₁₂. Desse modo, como a série temporal observada apresenta tendência e comportamento sazonal, pode-se constatar que houve a necessidade de realizar uma diferenciação que é indicada pelo segundo termo ($d = 1$) da parcela não sazonal (p,d,q) deste modelo, bem como uma diferenciação sazonal indicada pelo segundo termo ($D = 1$) da parcela sazonal. Os parâmetros estimados para o modelo SARIMA(0,1,1)(0,1,1)₁₂, bem como os

critérios AIC e BIC e as medidas de acurácia obtidas para este modelo na porção de dados de teste, são apresentados na Tabela 8.

Tabela 8 - Parâmetros do modelo SARIMA(0,1,1)(0,1,1)₁₂ e medidas de acurácia para a série de movimentação de passageiros na porção de dados de teste (12 últimas observações)

Modelo	Parâmetros	Erro padrão	AIC	BIC	MAE	MSE	MAPE
SARIMA (0,1,1)(0,1,1) ₁₂	$\Phi_1 = -$ 0,2315	0,0 80	2,74	2,75	26	115,0	1,4
	$\Theta_1 = -$ 0,4560	0,0 63 5	6,33	5,93	2,4 7	12,74	9

O teste de Ljung-Box retornou um p-valor igual a 0,377, indicando que os resíduos do modelo SARIMA(0,1,1)(0,1,1)₁₂ não são correlacionados, podendo então ser usado para prever a movimentação de passageiros no Brasil.

A Figura 8 apresenta os valores observados da série temporal de movimentação de passageiros, valores ajustados que foram previstos pelo modelo SARIMA(0,1,1)(0,1,1)₁₂ e valores previstos pelo mesmo modelo para os 12 períodos fora da amostra (março de 2020 a fevereiro de 2021). Ressalta-se que a área sombreada pela cor azul, para o período fora da amostra, representa os intervalos de confiança de 95% para as previsões obtidas.

Figura 8 - Série temporal observada, valores ajustados aos dados e valores previstos para fora da amostra pelo modelo SARIMA(0,1,1)(0,1,1)₁₂



A partir da obtenção das previsões individuais pelos modelos de Holt-Winters Aditivo e SARIMA(0,1,1)(0,1,1)₁₂, obteve-se as previsões combinadas pelos três modelos apresentados para a série temporal de movimentação de passageiros. A Tabela 9 apresenta os desempenhos dos dois modelos de previsões individuais e dos três de combinação em termos das medidas de acurácia consideradas (MAE, MSE e MAPE) na porção de dados de teste.

Tabela 9 - Medidas de acurácia dos modelos de previsões individuais e de combinação para a série de movimentação de passageiros na porção de dados de teste (12 últimas observações)

Modelos	MAE	MSE	MAPE
Holt-Winters Aditivo	283,30	133.634,51	1,62
SARIMA(0,1,1)(0,1,1) ₁₂	262,47	115.012,74	1,49
Previsão combinada (Média Aritmética)	271,29	113.966,98	1,54
Previsão combinada (Variância Mínima)	269,16	112.643,45	1,53
Previsão combinada (Regressão Linear)	266,05	115.894,04	1,50

Pode-se verificar, na Tabela 9, que os modelos SARIMA(0,1,1)(0,1,1)₁₂ e Previsão combinada por regressão linear apresentaram praticamente os mesmos desempenhos em termo das medidas de acurácia. Desse modo, o modelo SARIMA(0,1,1)(0,1,1)₁₂ foi escolhido para realizar previsões futuras da movimentação de passageiros nos aeroportos brasileiros, considerando o mesmo critério apresentado anteriormente para a série temporal de movimentação de cargas.

A Tabela 10 apresenta os valores previstos para a série temporal de movimentação de passageiros pelo modelo SARIMA(0,1,1)(0,1,1)₁₂ (Coluna A), valores observados (Coluna B), diferença entre os valores observados e previstos e a variação percentual entre os valores previstos e observados durante o primeiro ano da pandemia da Covid-19 (março de 2020 a fevereiro de 2021).

Tabela 10 - Valores previstos pelo modelo SARIMA(0,1,1)(0,1,1)₁₂, valores observados, diferença e variação percentual para a série de movimentação de passageiros para o período fora da amostra

Períodos	SARIMA (0,1,1)(0,1,1) ₁₂ (A)	Valores Observados (B)	Diferença (B) – (A)	Variação Percentual [(B) – (A)]/(A)
Março/2020	18.561	11.486	-7.075,30	-0,3812
Abril/2020			-	
	17.749	867	16.881,36	-0,9511
Maio/2020			-	
	17.539	1.170	16.369,23	-0,9333
Junho/2020			-	
	17.208	1.836	15.371,56	-0,8933
Julho/2020			-	
	20.681	3.309	17.372,20	-0,8400
Agosto/2020			-	
	18.982	4.374	14.607,41	-0,7696
Setembro/2020			-	
	18.617	5.894	12.723,23	-0,6834
Outubro/2020			-	
	19.542	7.996	11.545,72	-0,5908
Novembro/2020	19.037	10.034	-9.002,93	-0,4729
Dezembro/2020	20.815	11.913	-8.902,03	-0,4277
Janeiro/2021	21.873	16.445	-5.427,80	-0,2482
Fevereiro/2021	18.183	8.377	-9.805,70	-0,5393
Total	228.786	83.701	-145.084	-0,6341

Observa-se, na Tabela 10, que o mês de abril de 2020 foi o que sofreu o maior impacto, isto é, maior redução (-95,11%) na movimentação de passageiros nos aeroportos brasileiros, seguido pelos meses de maio, junho e julho que sofreram reduções nos volumes observados (coluna B) acima de 80% quando comparados com os valores previstos (coluna A). O volume total previsto de movimentação de passageiros durante o primeiro ano da pandemia foi 228.786 mil, enquanto o observado foi de 83.701 mil. Assim, é possível observar que o volume movimentado de passageiros foi 63,41% menor que o volume previsto para o período considerado (março de 2020 a fevereiro de 2021).

5 CONSIDERAÇÕES FINAIS

No presente trabalho, foi analisado o impacto da pandemia da COVID-19 sobre a movimentação de cargas e passageiros nos aeroportos brasileiros através de modelagens e previsões de séries temporais.

Foi possível observar que o modelo de Holt-Winters Aditivo foi o que apresentou o melhor desempenho, considerando as medidas de acurácia MAE, MSE e MAPE, respectivamente, para a série temporal de movimentação de cargas. Além disso, o SARIMA(2,0,2)(1,1,0)₁₂ foi o modelo selecionado automaticamente pelo software R para obter previsões individuais pela classe dos modelos SARIMA para esta mesma série temporal. Após a comparação dos desempenhos dos modelos de previsão individuais e combinadas, foi selecionado o modelo de Holt-Winters Aditivo para prever a movimentação futura de cargas nos aeroportos brasileiros.

Já para a série temporal de movimentação de passageiros, o modelo de Holt-Winters Aditivo também foi o mais acurado e o modelo SARIMA(0,1,1)(0,1,1)₁₂ foi o selecionado pelo R. Da mesma forma, quando comparados os desempenhos das previsões individuais e combinadas, pôde-se constatar que o modelo SARIMA(0,1,1)(0,1,1)₁₂ foi o mais recomendado para prever a movimentação futura de passageiros nos aeroportos brasileiros.

Logo, foi possível constatar que o volume observado de movimentação de cargas foi 28,55% inferior ao volume previsto pelo modelo de Holt-Winters Aditivo para o período considerado (março de 2020 a fevereiro de 2021). Da mesma forma, o volume observado de movimentação de passageiros foi 63,41% inferior ao volume previsto pelo modelo SARIMA(0,1,1)(0,1,1)₁₂ para o primeiro ano da pandemia da COVID-19.

Por fim, para trabalhos futuros recomenda-se realizar análises de outras técnicas de previsão de séries temporais para modelar e prever as mesmas séries analisadas neste projeto de pesquisa. Além disso, sugere-se que sejam avaliados os impactos da pandemia em cada um dos 10 principais aeroportos dos *rankings* de movimentação de cargas e passageiros, o que permitirá aos seus operadores obter um diagnóstico mais realístico do impacto da pandemia nos mesmos.

REFERÊNCIAS

BATES, J. M.; GRANGER, C. W. J. The Combination of Forecasts. **OR**, v. 20, n. 4, p. 451, 19 dez. 1969.

BAYER, F. M.; SOUZA, A. M. Wavelets e modelos tradicionais de previsão: um estudo comparativo. **Revista Brasileira de Biometria**, v. 28, p. 40-61, 2010.

BOX, G.; JENKINS, G. **Time series analysis, forecasting and control**. San Francisco: Holden-Day, 1976. 575 p.

CHOI, J. H. Changes in airport operating procedures and implications for airport strategies post-COVID-19. **Journal of Air Transport Management**, v. 94, p. 102065, 2021.

COSTANTINI, M.; PAPPALARDO, C. A hierarchical procedure for the combination of forecasts. **International Journal of Forecasting**, v. 26, n. 4, p. 725–743, 1 out. 2010.

COSTA, A. S.; FÔRO, G. S. S.; VIEIRA, J. L. COVID-19 e as cadeias de suprimentos: uma revisão bibliográfica dos principais impactos no Brasil. **Revista Vianna Sapiens**, v. 11, n. 2, p. 1–28, 2020.

DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, v. 22, n. 3, p. 443–473, 2006.

FERREIRA, L. D.; GARCIA, C. M.; HENKES, J. A. Análise dos processos operacionais da empresa aérea Latam Brasil referente aos impactos ambientais em suas operações com as aeronaves Airbus 320. **Revista Gestão & Sustentabilidade Ambiental**, v. 9, n. 2, p. 96–119, 2020.

GRANGER, C. W. J.; RAMANATHAN, R. Improved methods of combining forecasts. **Journal of Forecasting**, v. 3, n. 2, p. 197–204, 1984.

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. **International Journal of Forecasting**, v. 20, n. 1, p. 5–10, 2004.

HOTLE, S.; MUMBOWER, S. The impact of COVID-19 on domestic U.S. air travel operations and commercial airport service. **Transportation Research Interdisciplinary Perspectives**, v. 9, p. 100277, 2021.

HYNDMAN, R. J.; ATHANASOPOULOS, G. Optimally Reconciling Forecasts in a Hierarchy. **Foresight: The International Journal of Applied Forecasting**, n. 35, p. 42–48, 2014.

LEVINE, D. M.; STEPHAN, D. F.; SZABAT, K. A. **Estatística - Teoria e Aplicações - Usando Microsoft Excel**. 6. ed. Rio de Janeiro: LTC, 2016.

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

NASSIF, V. M. J.; CORRÊA, V. S.; ROSSETTO, D. E. Estão os empreendedores e as pequenas empresas preparadas para as adversidades contextuais? Uma reflexão à luz da pandemia do Covid-19. **Revista de Empreendedorismo e Gestão de Pequenas Empresas**, v. 9, n. 2, p. 1, 2020.

SILVA, R. B. Z.; BRIGANTE, C. S.; OLIVEIRA, G. P. F.; LUCENA, I. B. E. Uso de modelos de previsão de séries temporais para avaliação do impacto da pandemia da Covid-19 sobre a movimentação de passageiros no aeroporto internacional de Várzea Grande-MT. In: Anais do 35º Congresso de Pesquisa e Ensino em Transportes da ANPET, 2021.

SENNA, V.; SOUZA, A. M. Consequências da pandemia de covid-19 para a aviação civil no Brasil. **Exacta**, 2021. doi: <https://doi.org/10.5585/exactaep.2021.19744>.

SUN, X.; WANDEL, S.; ZHANG, A. How did COVID-19 impact air transportation? A first peek through the lens of complex networks. **Journal of Air Transport Management**, v. 89, p. 101928, 2020.

WEBBY, R.; O'CONNOR, M. Judgemental and statistical time series forecasting: a review of the literature. **International Journal of Forecasting**, v. 12, n. 1, p. 91–118, 1996.

Como Referenciar este Artigo, conforme ABNT:

SILVA, R. B. Z; BRIGANTE, C. S; NICOLAU, C. O; AIRES, F. F. C; Impacto da Covid-19 Sobre as Movimentações dos Aeroportos Brasileiros. **Rev. FSA**, Teresina, v. 20, n. 9, art. 7, p. 139-164, set. 2023.

Contribuição dos Autores	R. B. Z. Silva	C. S. Brigante	C. O. Nicolau	F. F. C. Aires
1) concepção e planejamento.	X	X		
2) análise e interpretação dos dados.	X			
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X	X	X
4) participação na aprovação da versão final do manuscrito.	X	X	X	X