

Impacto da pandemia de COVID-19 na demanda por transporte aéreo no Brasil

Christopher Feitosa (PUC-Rio)
christopherfeitosa@yahoo.com.br

Fernando Luiz Cyrino Oliveira (PUC-Rio)
cyrino@puc-rio.br



A pandemia de COVID-19 gerou impacto em diferentes indústrias, desde o setor primário ao setor terciário, com quedas de demanda acentuadas e perdas econômicas. O mercado da aviação foi um dos mais afetados no mundo, com quedas na demanda de passagens aéreas e transporte de carga. O Objetivo do presente artigo foi avaliar quantitativamente o impacto da pandemia no transporte aéreo de passageiros, carga e correios no Brasil. O artigo utiliza a técnica de bagging para prever as demandas em 2020 caso não houvesse a COVID-19 e compara com os dados observados na realidade, afetados pela pandemia.

Os resultados mostram que a técnica de bagging apresenta os melhores resultados na previsão de demanda por transporte aéreo. O impacto foi observado com destaque para quedas de 93,4% e 91,7% na demanda por passagens aéreas e 67,2% e 54,2% na demanda por transporte de carga, ambos nos meses de abril e maio.

Palavras-chave: COVID-19, Simulação, Bagging, Transporte Aéreo.

1. Introdução

Em 11 de março de 2020 a Organização Mundial de Saúde (OMS) declarava pandemia da doença COVID-19 (Gumbrecht e Howaer, 2020). Ao longo do ano o número de casos aumentou de forma exponencial em diversos países, provocando uma crise sanitária sem precedentes (Universidade John Hopkins, 2020). Para minimizar os efeitos da pandemia foram fundamentais medidas drásticas, que afetaram não apenas o dia a dia das pessoas, mas também diversos mercados e cadeias logísticas. Nicola et al. (2020) apontam diferentes indústrias afetadas pela pandemia, desde o setor primário ao terciário, com uma grande queda na demanda por commodities e produtos manufaturados e dificuldades logísticas impostas pelas restrições de deslocamento e perdas de empregos; em contraste com o aumento na demanda por alimentos (devido a tendência de estocar alimentos por parte dos consumidores) e por suprimentos médicos.

Segundo dados da Agência Nacional de Aviação Civil do Brasil (ANAC) o mercado de transporte aéreo foi um dos mais afetados com a pandemia, com uma queda percentual na demanda por passagens aéreas domésticas que chegou a 93,1% em abril de 2020, em relação aos dados de abril de 2019. Nicola et al. (2020) apresentam os efeitos na aviação mundial ainda no início da pandemia causados pelas restrições a viagens, com agencias como a Airlines for America e UK Airlines necessitando de aportes financeiros dos governos locais para se manterem ativas. Apesar da influencia negativa da pandemia na indústria da aviação, com a necessidade de criação de um plano logístico de vacinação em 2021 o transporte aéreo terá um papel fundamental (AIR CARGO WORLD, 2020).

Dantas et al. (2017) abordam a importância do mercado da aviação e sua relação com o desenvolvimento econômico regional, mostrando que economia e aviação estão relacionados, o que no contexto do presente artigo justifica o estudo de como a pandemia afetou a indústria aérea como consequência dos impactos econômicos. A relação entre a indústria do transporte aéreo e a economia também é destacada por Baker et al. (2015) e Green (2007). Barnhart et al. (2003) fazem um paralelo entre o crescimento do transporte aéreo, desde a época em que a indústria fornecia um produto de elite apenas para os tempos atuais nos quais a aviação se tornou um transporte em massa, e o desenvolvimento da pesquisa operacional como ciência. Segundo os autores é difícil de imaginar outro setor, que não o militar, com relação mais íntima a Pesquisa Operacional do que a indústria da aviação. Barnhart et al. (2003) comentam ainda sobre a importância de se desenvolver bons modelos de previsão de demanda para alimentar, com dados de qualidade, modelos de otimização, o que é também abordado por Marazzo et al.

(2010).

O objetivo do presente artigo é utilizar a técnica de bagging para realizar a previsão de demanda de transporte aéreo de passageiros e transporte aéreo de cargas e correios no Brasil para o ano de 2020, em um cenário no qual não houvesse a pandemia de COVID-19, para assim avaliar quantitativamente o impacto que a pandemia gerou na indústria da aviação. A avaliação desse impacto é muito importante do ponto de vista da tomada de decisões no processo de recuperação do mercado e da economia, assim como na compreensão da efetividade das medidas de restrição adotadas no país.

Este trabalho está estruturado nas seguintes seções: A seção atual de introdução contextualiza e justifica o problema abordado. A seção 2 apresenta o referencial teórico, com uma revisão sobre as técnicas de simulação e forecasting utilizadas neste trabalho. A seção 3 descreve a metodologia aplicada na pesquisa e os cenários de experimentação. A seção 4 apresenta os resultados obtidos e discute sobre os mesmos. A seção 5 finaliza o artigo descrevendo as conclusões obtidas com o trabalho realizado.

2. Referencial teórico

A técnica de *Bootstrap Aggregating*, também conhecida por “*Bagging*”, é uma metodologia de *machine learning* desenvolvida por Breiman (1996). Bergmeir et al. (2016) propõem uma metodologia para a utilização do *Bagging* na previsão de séries temporais e Dantas et al. (2017) utilizam essa metodologia como base para a previsão de demanda no transporte aéreo de passageiros em 14 países diferentes. Os autores citados dividem a metodologia conforme descrito nas subseções a seguir.

2.1. Decomposição

A Primeira etapa consiste no processo de decomposição da série temporal. Bergmeir et al. (2016) citam a técnica STL para decompor a série temporal analisada em sazonalidade, tendência e *remainder* (caso a série tenha os 3 componentes), conforme descrito por Cleveland et al. (1990);

2.2. Simulação

A segunda etapa consiste no processo de geração de cenários a partir da série temporal original. Na metodologia descrita por Bergmeir et al. (2016) e Dantas et al. (2017) os autores utilizam a simulação aplicando a técnica de *moving block bootstrap* (MBB) conforme proposto por

Künsch (1989), para gerar novas versões do *remainder* que variem, mas mantenham as características principais da série original;

2.3. Previsão

Existem diversas técnicas de forecasting citadas em trabalhos anteriores com diferentes aplicações, como o ARIMA por exemplo, utilizado por Contreras et al. (2003) para previsão de preços no mercado de geração de eletricidade. Segundo os resultados obtidos por Dantas et al. (2017), para a previsão de demanda de passageiros na aviação a melhor técnica é o Holt-Winters, proposto por Holt (1957) e Winters (1960) que pertence a uma série de técnicas denominada amortecimento exponencial (ETS). O método de Holt-Winters é categorizado como aditivo ou multiplicativo de acordo com o fator de sazonalidade. Segundo Cordeiro e Neves (2009) o Holt-Winters é aplicado quando a série possui sazonalidade e tendência, sendo o Holt-Winters aditivo descrito pelas equações 1,2,3 e 4 a seguir:

$$T_t = \alpha(X_t - S_{t-s}) + (1 - \alpha)(T_{t-1} + b_{t-1}) \quad (1)$$

$$b_t = \beta(T_t - T_{t-1}) + (1 - \beta)(b_{t-1}) \quad (2)$$

$$S_t = \gamma(X_t - T_t) + (1 - \gamma)(S_{t-s}) \quad (3)$$

$$\hat{X}_t(h) = T_t + h \times b_t + S_{t+h-rs} \quad (4)$$

As equações 5,6,7 e 8 descrevem o método de Holt-Winters Multiplicativo, como segue:

$$T_t = \alpha(X_t/S_{t-s}) + (1 - \alpha)(T_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta(T_t - T_{t-1}) + (1 - \beta)(b_{t-1}) \quad (6)$$

$$S_t = \gamma(X_t/T_t) + (1 - \gamma)(S_{t-s}) \quad (7)$$

$$\hat{X}_t(h) = (T_t + h \times b_t)S_{t+h-rs} \quad (8)$$

Onde T_t é o componente de nível ao fim do período após ajuste de sazonalidade; X_t é o valor atual ao final do período t ; S_{t-s} é o índice de amortecimento da sazonalidade “s” períodos antes; b_t é o valor de amortecimento da tendência no período “t”; enquanto α , β e γ são parâmetros do modelo.

2.4. Agregação

A etapa consiste na agregação de todos os cenários previstos na etapa de *forecasting*. Dantas et al. (2017) lista diferentes métodos de medição para esta etapa, como média simples dos

resultados, mediana dos cenários ou média ponderada por exemplo.

2.5. Avaliação dos resultados

Hyndman e Koehler (2006) apresentam várias métricas para avaliar os resultados obtidos por métodos de *forecasting*, dentre os quais o mais comum é o Erro percentual absoluto médio (MAPE) calculado segundo a equação 9.

$$MAPE = MEAN \left| \frac{100(Y_t - F_t)}{Y_t} \right| \quad (9)$$

Onde Y_t é a observação no tempo “t” e F_t é a previsão realizada para Y_t .

3. Metodologia

3.1. Coleta de Dados

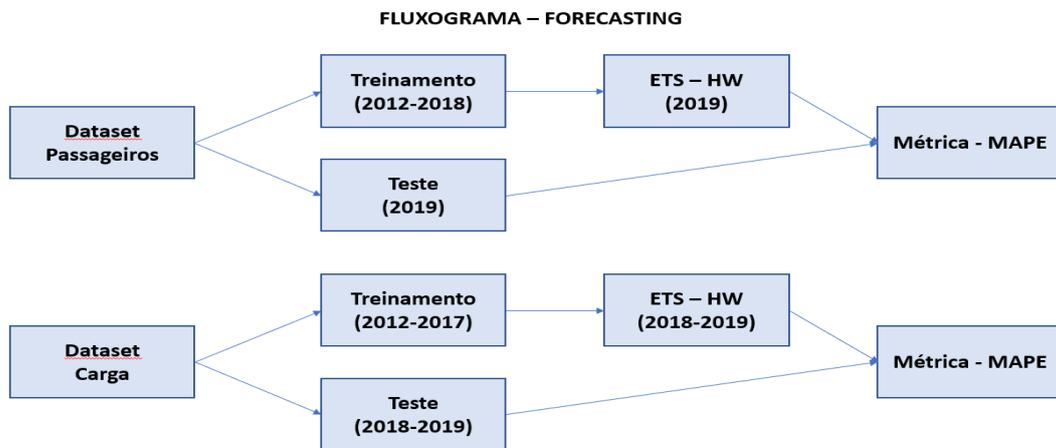
Dois *datasets* foram selecionados para o presente trabalho, ambos com dados entre 2012 e 2020 fornecidos pela Agência Nacional de Aviação Civil do Brasil (ANAC): O primeiro *dataset* é composto por dados de RPK doméstico, que mostram o número de passageiros-quilômetros pagos transportados ou, em outras palavras, a demanda por passagens aéreas domésticas no Brasil; O segundo *dataset* é composto por dados de demanda por transporte de carga e correio no país.

3.2. Análise dos Dados

Cada *dataset* foi testado com 4 técnicas diferentes: Holt-Winters Multiplicativo, Holt-Winters Aditivo, Holt-Winters Multiplicativo com *Bagging* e Holt-Winters Aditivo com *Bagging*.

Nos cenários sem *bagging*, após a coleta de dados o *dataset* é transformado em série temporal e separado em dados de treinamento e dados de teste. Para o *dataset* de transporte de passageiros os dados de treinamento foram selecionados de janeiro de 2012 a dezembro de 2018, enquanto os dados de teste foram selecionados de janeiro de 2019 a dezembro de 2019. O *dataset* de transporte de carga e correios por sua vez possui um perfil de dados mais complexo e variável, após experimentações definiu-se a melhor divisão dos dados em treinamento entre janeiro de 2012 e dezembro de 2017 e teste entre janeiro de 2018 e dezembro de 2019. A figura 1 demonstra o fluxograma para os experimentos sem *bagging*, realizados no software R.

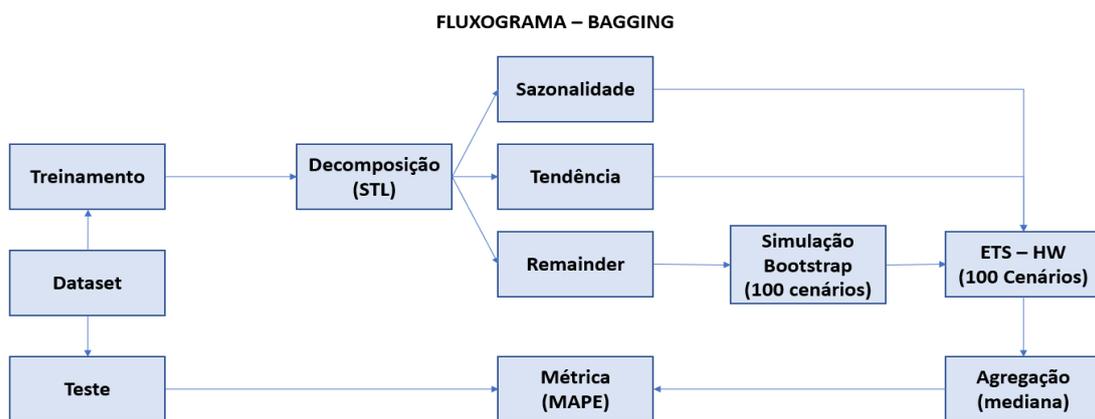
Figura 1- Fluxograma Forecasting



Fonte: Fornecido pelos autores

Nos demais cenários foi aplicada a técnica de *bagging*, conforme descrito no referencial teórico do presente artigo, com decomposição em sazonalidade, tendência e *remainder*, simulação do *remainder* utilizando Moving-Block Bootstrap para geração de 100 cenários a partir dos dados históricos originais, *forecasting* utilizando Holt-Winters para cada um dos 100 cenários e por fim agregação de todos os cenários previstos utilizando a mediana dos dados previstos. A metodologia é apresentada na figura 2.

Figura 2 - Fluxograma Bagging



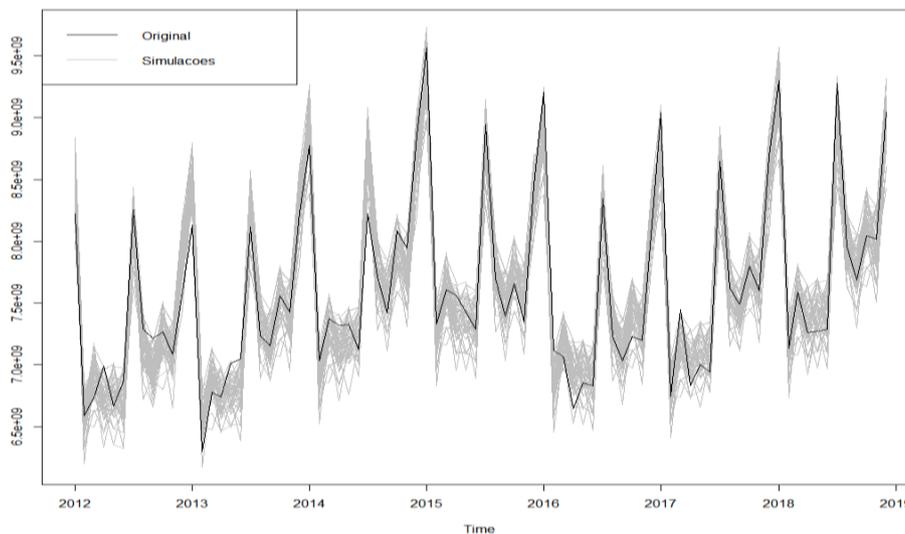
Fonte: Fornecido pelos autores

4. Resultados

4.1. Demanda de passageiros

Foram gerados 100 cenários a partir do *dataset* original, com dados de treinamento do modelo selecionados entre 2012 e 2018. A Figura 3 mostra os cenários criados pela simulação utilizando a técnica de *bootstrap*.

Figura 3 - Geração de Cenários: Demandas de passageiros



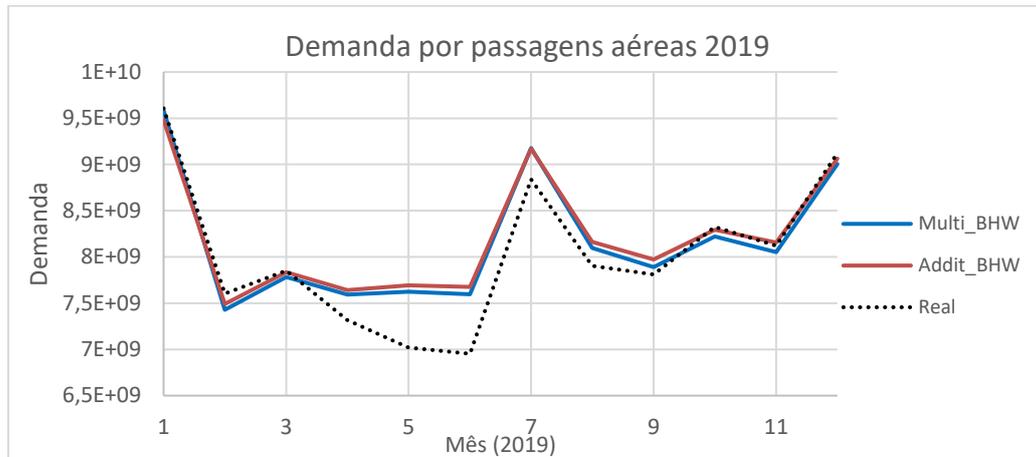
A Tabela 1 mostra os resultados obtidos de MAPE para as 4 técnicas realizadas: *Bagging* + Holt Winters Aditivo, *Bagging* + Holt Winters Multiplicativo, Holt Winters Aditivo e Holt Winters Multiplicativo. Como visto nos trabalhos anteriores, a etapa de simulação de bootstrap para geração de cenários reduz o erro na previsão, com o método multiplicativo apresentando o melhor resultado.

Tabela 1 - MAPE: Dataset passageiros

Método	MAPE
Multi Bagging HW	2,89
Addit Bagging HW	3,12
Multi Holt-Winters	3,14
Addit Holt-Winters	3,54

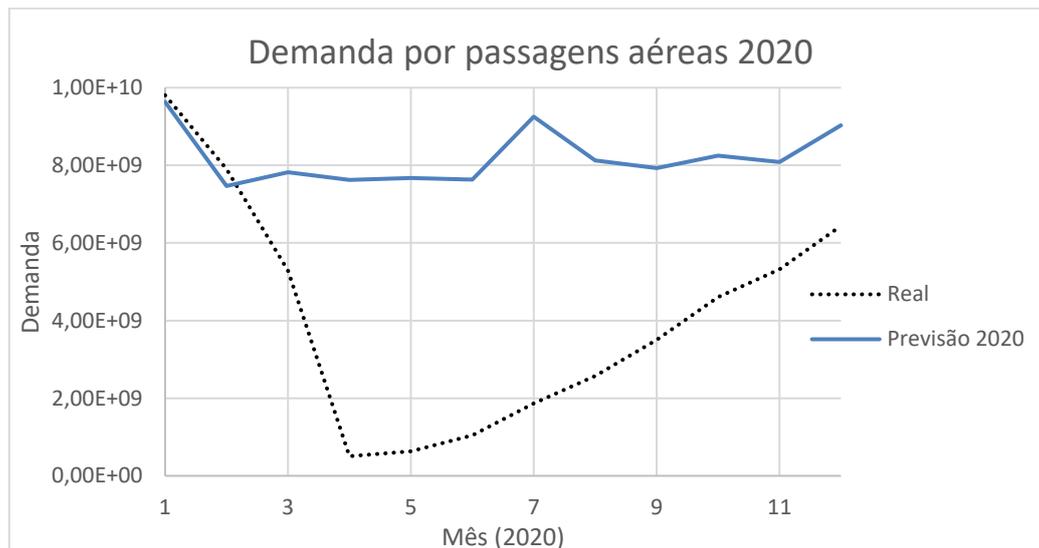
A Figura 4 mostra a comparação entre os valores reais dos dados de teste (ano 2019), e as duas melhores previsões feitas.

Figura 4 - Previsão demanda de passageiros (2019)



O gráfico ratifica que o modelo apresenta um erro muito pequeno, com um desvio maior apenas no intervalo entre o mês 4 e o mês 6 e confirma que o método do Bagging Holt-Winters é o que apresenta os melhores resultados e, portanto, essa foi a técnica utilizada para a previsão no ano de 2020. A Figura 5 apresenta o gráfico comparativo entre a previsão realizada pelo modelo para o ano de 2020 e os valores reais observados.

Figura 5 - Previsão demanda de passageiros (2020)



A Tabela 2 mostra a variação quantitativa entre os dados previstos para 2020 caso não houvesse a pandemia de COVID-19 e os dados observados com os efeitos da pandemia.

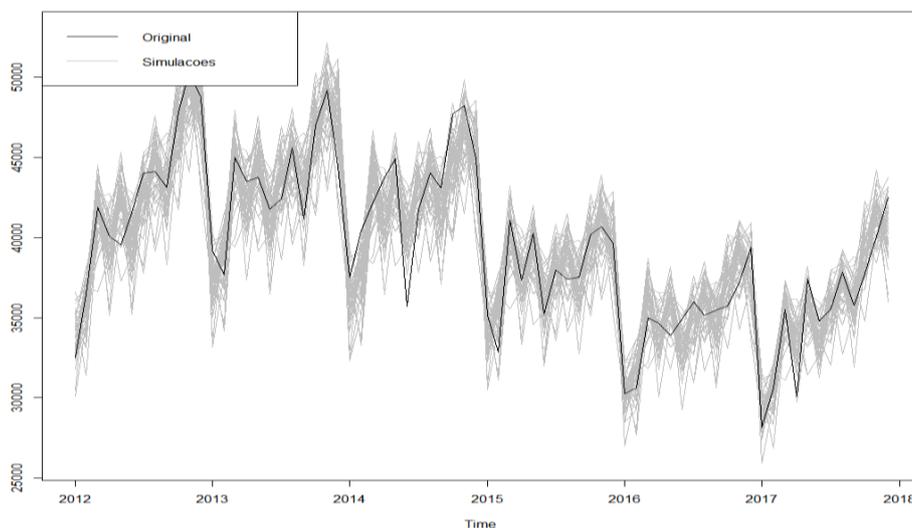
Tabela 2 - Impacto da pandemia na demanda de passageiros

Mês	Varição (%)
Janeiro	1,8
Fevereiro	5,9
Março	-32,4
Abril	-93,4
Maio	-91,7
Junho	-86,3
Julho	-79,8
Agosto	-68,4
Setembro	-55,9
Outubro	-44,2
Novembro	-34,2
Dezembro	-28,7

4.2. Demanda por transporte de carga e correios

O mesmo procedimento foi realizado para avaliar os impactos no transporte aéreo de carga, com 100 cenários gerados a partir dos dados históricos coletados entre 2012 e 2017, conforme a Figura 6.

Figura 6 - Geração de Cenários: Transporte de Carga



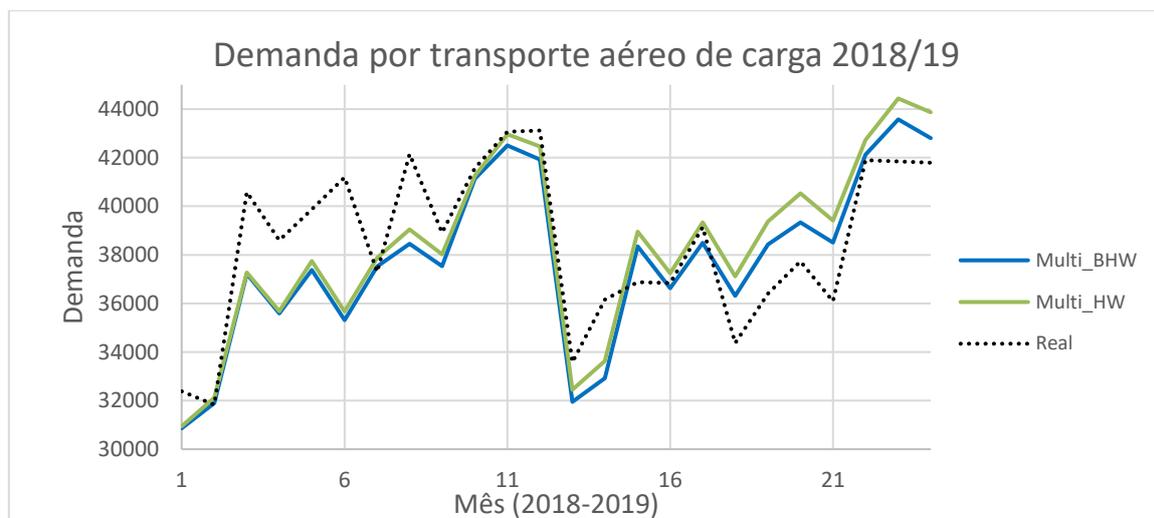
A Tabela 3 mostra os erros MAPE calculados para as técnicas utilizadas e, assim como para a demanda de passageiros, o resultado com melhor métrica foi obtido com os cenários simulados por *bootstrap* e o *forecasting* utilizando Holt-Winters Multiplicativo.

Tabela 3 - MAPE: Dataset Carga

Método	MAPE
Multi Bagging HW	4,64
Addit Bagging HW	5,03
Multi Holt-Winters	4,88
Addit Holt-Winters	5,09

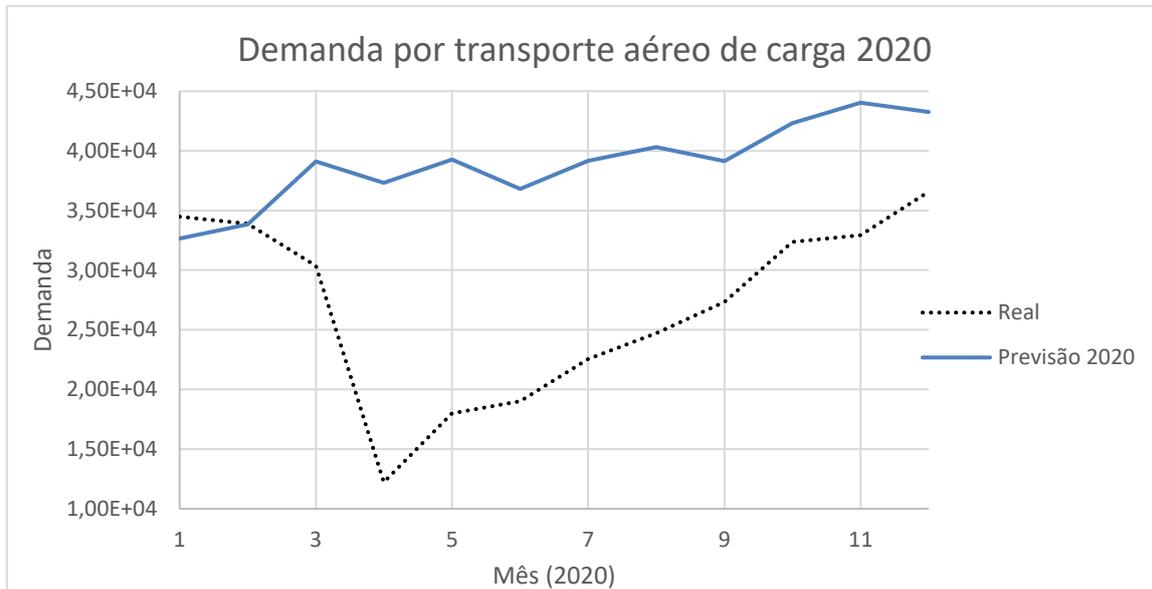
A Figura 7 mostra a comparação entre os dois melhores métodos de previsão para os dados de teste (anos 2018 e 2019) e os dados reais observados neste período. É possível observar de forma geral que os erros são maiores em comparação com os erros na previsão da demanda de passageiros, porém ainda assim é um erro pequeno e a previsão segue um comportamento próximo aos dados observados na realidade.

Figura 7 - Previsão Transporte de carga (2018/19)



Como observado, novamente o método de *Bagging* + Holt-Winters Multiplicativo apresentou a melhor previsão, sendo então o modelo utilizado para a previsão para o ano de 2020. O gráfico apresentado na Figura 8 mostra o comparativo entre a previsão para o transporte de carga e correios no ano de 2020 no caso hipotético de não ter ocorrido a pandemia de COVID-19 e os dados reais observados neste ano afetados pela pandemia.

Figura 8 - Previsão Transporte de carga (2020)



As diferenças entre o previsto e o observado são reiteradas na tabela 4, pelo cálculo da variação percentual entre os valores.

Tabela 4 - Impacto da pandemia no transporte de carga

Mês	Varição (%)
Janeiro	5,6
Fevereiro	0,1
Março	-22,4
Abril	-67,2
Mai	-54,2
Junho	-48,4
Julho	-42,4
Agosto	-38,7
Setembro	-30,2
Outubro	-23,5
Novembro	-25,2
Dezembro	-15,4

4.3. Discussão

Os resultados demonstram quantitativamente o impacto da pandemia de COVID-19 diretamente nas demandas por transporte aéreo, tanto de passageiros (mercado mais afetado) quanto de carga e correios (menos afetado). É interessante observar que a maior queda entre os

valores previstos para 2020 e os observados ocorre no mês de abril para ambos os mercados, que não representa o mês auge da pandemia no Brasil, mas sim o primeiro mês completo impactado. Pode-se concluir que isso ocorre devido às medidas mais restritivas no mês de abril, com um relaxamento das medidas de contenção ao longo do ano reduzindo o “*déficit*” causado pela pandemia na indústria da aviação. Os experimentos realizados mostram um erro reduzido para o método de previsão proposto utilizando o *bagging*; para a demanda por passagens aéreas, no geral a previsão é mais “fácil”, pois a série temporal de dados históricos entre 2012 e 2018 mostram tendência e sazonalidade bem definidas e justificadas pelo aumento na demanda anual ao longo do tempo, com o crescimento do setor e popularização do transporte aéreo, como comentado na seção de introdução do presente artigo, assim como pela sazonalidade anual, com a demanda variando mês a mês de acordo com maiores procuras naturais em períodos de final/início de ano por exemplo, que coincidem com férias escolares e festas/feriados. O perfil do transporte aéreo de cargas por sua vez é bem mais complexo; observa-se que os dados coletados variam anualmente com cenários políticos, além claro de outros fatores que podem ou não decorrer de cenários políticos e/ou influenciar cenários políticos, como cotação do dólar e preço do petróleo, de forma que o perfil da demanda por transporte de carga representa melhor o cenário do mercado brasileiro do que a demanda por passagens aéreas. A maior variação nos dados aumenta a dificuldade na previsão, o que explica os resultados piores de MAPE obtidos para transporte de carga que, porém, ainda é um erro consideravelmente baixo, e o gráfico comparativo mostra que a previsão para os anos 2018/2019 segue um perfil bem próximo ao real observado, validando o modelo que foi utilizado para a previsão no ano de 2020.

Os resultados obtidos para o transporte de carga apresentaram menor queda em relação a previsão do modelo para 2020 do que os resultados observados para o transporte de passageiros, o que de certa forma já era esperado, pois o impacto na demanda de passageiros é mais forte devido as medidas de restrição, e apenas após a flexibilização ao longo do ano que a redução passa a ser justificada pelo receio da população e pela preferência por trabalho *home-office* quando possível. A redução no transporte de carga por sua vez mostra diretamente o impacto da pandemia no mercado brasileiro e na cadeia logística.

5. Conclusões

Conforme apresentado na seção de introdução, os objetivos para o presente artigo foram alcançados. Dentre as técnicas testadas, a previsão pelo método de Holt-Winters com *Bagging*, utilizando simulação de bootstrap nos resíduos da série histórica, apresentou o melhor resultado

para previsão de demanda por passagens aéreas domésticas e de demanda por transporte aéreo de cargas e correios no Brasil, com erro MAPE respectivamente de 2,89 e 4,64. Com o melhor modelo validado foi possível realizar a previsão de demanda para o ano de 2020 caso não houvesse a pandemia de COVID-19 e assim comparar com os dados reais observados sob o efeito da pandemia. O impacto observado foi calculado pela queda percentual entre o valor de demanda real em 2020 e o valor previsto pelo modelo, com destaque para quedas de 93,4% e 91,7% na demanda por passagens aéreas nos meses de abril e maio. As quedas observadas para o transporte de carga foram menores, mas ainda assim significativas, com destaque para as quedas de 67,2% e 54,2% também nos meses de abril e maio.

Os resultados mostraram que o transporte de carga é mais sensível no geral a variações em cenários políticos e econômicos do país, pois representam melhor o perfil de mercado no Brasil em cada época; porém no contexto da pandemia, foi menos afetado em relação a demanda por transporte de passageiros.

Os métodos descritos neste trabalho e os resultados obtidos auxiliam na tomada de decisões futuras e no estudo do impacto da COVID-19 no mercado aéreo brasileiro, visto que a recuperação desta crise requer estratégias para lidar com as incertezas que ainda permeiam a pandemia, recuperar o mercado e a economia do país.

A aplicação do *bagging* na previsão do transporte de cargas e correios apresentou um erro consideravelmente pequeno dada a grande volatilidade dos dados, de forma que aprimorar os estudos com esse enfoque, em conjunto com análises mais detalhadas de como esta demanda é atrelada à diferentes cadeias logísticas de produção e transporte de carga, e como esses dados são afetados por cenários políticos e econômicos é uma contundente sugestão para trabalhos futuros, visto que trabalhos nesse contexto apresentam grande importância, sendo aplicáveis na indústria não apenas em momentos de crise.

REFERÊNCIAS

Air Cargo World (2020). Passenger freighters ‘good solution’ for vaccine airfreight challenges. Disponível em: <https://aircargoworld.com/news/specialty-cargo/passenger-freighters-good-solution-for-vaccine-airfreight-challenges/>. Acessado em 12/12/2020.

BAKER, D.; MERKERT, R.; KAMRUZZAMAN, M. Regional aviation and economic growth: cointegration and causality analysis in Australia. *Journal of Transport Geography*, Elsevier, v. 43, p. 140–150, 2015.

- Barnhart, C., Belobaba, P., Odoni, A.R. (2003). Application of Operations Research in the Air Transport Industry. *Transportation Science*. 37(4). 368-391.
- Bergmeir, C.N., Hyndman, R.J., Benitez, J.M. (2016). Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation. *International Journal of Forecasting*. 32 (2). 303-312.
- Breiman, L. (1996). Bagging predictors. *Machine Learning*. 24(2). 123-140.
- Cleveland, R.B., Cleveland, W.S., McRae, J.E., Terpenning, I. (1990). STL: a seasonal-trend decomposition procedure based on loess. *J. Off. Statistics*. 6. 3-73.
- Contreras, J., Espínola, R., Nogales, F.J., Conejo, A.J. (2003). ARIMA models to predict next-day electricity prices. *IEEE Transactions on Power Systems*. 18(3). 1014-1020.
- Cordeiro, C., Neves, M.M. (2009). Forecasting time series with boot.expos procedure. *REVSTAT – Statistical Journal*. 7(2). 135-149.
- Dantas, T.M., Oliveira, F.L.C., Repolho, H.M.V. (2017). Air transportation demand forecast through Bagging Holt Winters methods. *Journal of Air Transport Management*. 59. 116-123.
- GREEN, R. K. Airports and economic development. *Real estate economics*, Wiley Online Library, v. 35, n. 1, p. 91–112, 2007.
- Gumbrecht J, Howard J. WHO declares novel coronavirus outbreak a pandemic. CNN: 2020 Mar 11. Disponível em: <https://edition.cnn.com/2020/03/11/health/coronavirus-pandemic-world-health-organization/index.html>. Acessado em 07/04/2020.
- Holt, C.C. (1957). *Forecasting Trends and Seasonals by Exponentially Weighted Averages*. Carnegie Institute of Technology. Pittsburgh ONR memorandum no.52.
- Hyndman, R.J., Koehler, A.B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*. 22. 679-688.
- Künsch, H.R. (1989). The jackknife and the bootstrap for general stationary observations. *Ann.*

Statistics. 17(3). 1217-1241.

Marazzo, M., Scherre, R., Fernandes, E. (2010). Air Transport demand and economic growth in Brazil: a time series analysis. *Transp. Res. Part e Logist. Transp. Rev.* 46(2), 261-269.

Nicola, M., Alsafi, Z., Sohrabi, C., Kerwan, A., Al-Jabir, A., Iosifidis, C., Agha, M., Agha, R. (2020). The sócio-economic implications of the coronavirus pandemic (COVID-19): A review. *International Journal of Surgery.* 78. 185-193.

Universidade John Hopkins, 2020. COVID-19 Dashboard by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University. Disponível em:
<https://coronavirus.jhu.edu/map.html>. Acessado em 13/12/2020.

Winters, P.R. (1960). Forecasting sales by exponentially weighted moving Average. *Manag. Sci.* 6. 324-342.