BAGGING ETS NA PREVISÃO DE DEMANDAS DE REFIS DE PRODUTOS QUÍMICOS PARA UMA PLATAFORMA DE PETRÓLEO DA BACIA DE CAMPOS

BRUNA BITTENCOURT DA COSTA BRITO
UNIVERSIDADE FEDERAL FLUMINENSE - UFF
Rua Recife, s/n, Jardim Bela Vista, Rio das Ostras, RJ - Brasil - 28895-532.
brunabcbrito@gmail.com

ANA PAULA BARBOSA SOBRAL
UNIVERSIDADE FEDERAL FLUMINENSE - UFF
Rua Recife, s/n, Jardim Bela Vista, Rio das Ostras, RJ - Brasil - 28895-532.
ana_sobral@id.uff.br

RESUMO

A utilização da técnica de *Bagging (Bootstrap Aggregating*) associada a métodos tradicionais de previsão de demanda de séries temporais vem sendo expandida, dado a expressividade dos resultados alcançados. Este trabalho tem por objetivo realizar previsões de demanda de refis de produtos químicos enviados a uma plataforma de petróleo *offshore*. Para isso, são aplicados os métodos de Média Móvel, Amortecimento Exponencial Simples e o *Bagging* ETS, que é o método que combina a técnica de *Bagging* (*Bootstrap Aggregating*) com o método de Amortecimento Exponencial Simples. Os resultados mostram que a abordagem *Bagging* ETS é capaz de produzir resultados com acurácia, contribuindo como ferramenta de planejamento e controle logístico para plataformas de petróleo *offshore*.

PALAVRAS CHAVE. Previsão, *Bagging*, Indústria *Offshore*.

Tópicos. EN&PG – PO na Área de Energia, Petróleo e Gás; POI – PO na Indústria.

ABSTRACT

The use of the Bagging technique (Bootstrap Aggregating) associated with traditional methods of forecasting demand for time series has been expanded, given the expressiveness of the results achieved. This work aims to make demand forecasts for chemical products refills sent to an offshore oil rig. For this, the Moving Average, Simple Exponential Smoothing and Bagging ETS methods are applied, which is the method that combines the Bagging technique (Bootstrap Aggregating) with the Simple Exponential Smoothing method. The results show that the Bagging ETS approach can produce results with accuracy, contributing as a planning and logistical control tool for offshore oil rigs.

KEYWORDS. *Forecasting*, *Bagging*, *Offshore Industry*.

Paper topics: EN&PG - OP in the Energy, Oil and Gas; POI – OP in the Industry.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Introdução

As plataformas de produção de petróleo *offshore* são abastecidas por aeronaves e embarcações para que possam produzir initerruptamente, sendo este segundo o meio de transporte responsável por mais de 80 % da movimentação de cargas realizada. É uma intensa logística, a qual envolve diversas etapas entre fornecedores e armazéns localizados em terra, além de sofrer as influências das condições meteorológicas (vento, correnteza).

Dentre os diversos volumes enviados às plataformas – contentores, caixas, cestas, *skids* metálicos, refis de produtos químicos, entre outros – merecem destaque os refis de produtos químicos, visto que representam cerca de 50% do total de cargas movimentados em uma plataforma. A produção, processamento e escoamento do petróleo depende de inúmeros produtos químicos, os quais são transportados para a plataforma em refis de 5000 litros e 1500 litros.

A ausência de um planejamento confiável, gera altas despesas com a priorização de barcos em emergência, além de paradas indesejadas de produção e vulnerabilidade na segurança das pessoas e das instalações. Outro fator relevante é a necessidade de espaços físicos maiores para estoque, o que gera custos elevados com construções de galpões ou aluguéis para armazenagem dos materiais não transportados no prazo.

Existem diversas ferramentas que podem auxiliar na previsão de demandas para séries temporais, sendo as mais tradicionais as seguintes: Médias Móveis, Amortecimento Exponencial e a modelagem Box e Jenkins (ou seja, a família ARIMA). Apesar destes métodos produzirem bons resultados, há uma constante busca em resultados cada vez mais precisos, o que pode ser alcançados através da aplicação de métodos de conjunto (*ensembles methods*). Trata-se de técnicas relativamente simples e capazes de aumentar a capacidade de generalização de soluções baseadas em aprendizado de máquina [Tsoumakas et al 2005].

Neste contexto, a aplicação de técnicas de redistribuição dos dados (*Bootstrapping*), proposta por [Efron 1979], como meio de gerar componentes diversos a serem agregados, seja por voto majoritário ou ponderado, tem sido bastante difundido nas últimas décadas, por se tratar de técnicas capazes de aumentar a capacidade de generalização de soluções baseadas em aprendizado de máquina. Dentre os métodos de conjunto (*ensembles methods*) utilizados para essa aplicação em séries temporais, destaca-se o *Bagging (Bootstrap Aggregating)*, de [Breiman 1996].

[Dantas e Oliveira 2015] afirmam que métodos de geração de *ensembles* para se aprimorar previsões quando estes são combinados com métodos clássicos de séries temporais, são capazes de gerar previsões com maior acurácia nos resultados.

O presente artigo emprega três métodos de previsão de demanda para dois tipos de refis de produtos químicos movimentados entre uma plataforma de petróleo da Bacia de Campos e os barcos que realizam seu suprimento, a partir da aplicação dos métodos de Médias Móveis, Amortecimento Exponencial Simples e o *Bagging* ETS, que associa técnica de reamostragem com o método de Amortecimento Exponencial Simples. Os resultados dos métodos empregados foram comparados pelo erro de previsão MAD e validados pelo critério 4MAD, onde será selecionado o que apresentar melhor desempenho.

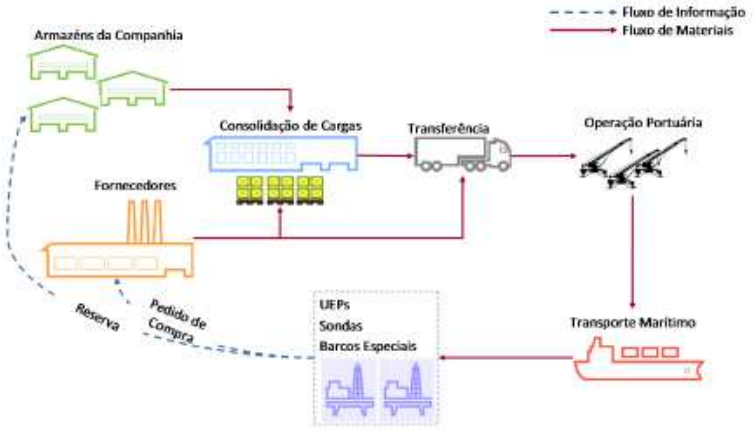
2. Referencial Teórico

2.1. Estrutura Logística *Offshore*

A estrutura logística *offshore* é complexa e envolve fornecedores, nacionais e internacionais, armazéns e terminais portuários, até o atendimento às unidades marítimas. A Figura 1 expressa o fluxo do atendimento do transporte até as plataformas.

Galoá { Este trabalho foi publicado utilizando o Galoá proceedings

Figura 1 – Fluxo do Sistema Logístico *Offshore*



Fonte: [Lopes 2011]

De acordo com [Ferreira Filho 2015], o fluxo de materiais é acompanhado por um fluxo de informação, o qual inicia através de um pedido da Unidade Marítima ao detentor do material, que pode ser um armazém próprio ou um fornecedor (nacional ou internacional). Os pedidos são emitidos e, quando atendidos pelo fornecedor, são transformados em uma ou mais Requisições de Transporte (RTs), que é o documento gerado no sistema SAP ERP, o qual contém toda a informação sobre a carga que será transportada.

A partir daí, o material é entregue à Consolidação de Cargas, a qual é responsável por coletar as cargas expedidas pelos armazéns ou fornecedores e prepará-las para serem transportadas. As RTs são levadas ao status de "Liberada para Programação" e o setor responsável pelo transporte terrestre da carga até o porto é comunicado e recebe um prazo para atender essa solicitação.

A operação portuária recebe a carga, efetua uma triagem, a fim de verificar se há alguma não conformidade entre a carga, sua embalagem e a documentação. Em caso positivo, a carga segue para o pré-embarque, local onde as cargas ficam aguardando para serem alocadas nas embarcações.

Após serem liberadas na triagem, a RT recebe o *status* de "Programada", ou seja, a carga será alocada em uma embarcação que a transportará até a unidade marítima de destino.

Dentre as cargas transportadas a plataformas de petróleo, podemos destacar: rancho, produto químico, motores, compressores, bombas, parafusos, chapas metálicas, materiais para montagem de andaime, solda, equipamentos de proteção individual (EPI), materiais de limpeza, higiene pessoal e de escritório, medicamentos, tinta, entre outros. Esses insumos são acondicionados em embalagens selecionadas pela equipe de consolidação de cargas, as quais levam em consideração o tipo de carga para empregar o mais seguro para a operação de movimentação de carga, tanto entre o píer e o barco, quanto entre o barco e a plataforma.

Cada carga tem suas particularidades, quanto ao tipo de contentor que deve ser utilizado para o seu transporte. Acondicionar uma carga para o seu transporte é responsabilidade do carregador, o qual deve assegurar que os requisitos de segurança estão sendo atendidos, ou seja, que a movimentação desta carga não oferece risco às pessoas e nem ao patrimônio envolvido.

2.1.1. Refil de Produto Químico

Os produtos químicos são essenciais para a produção, processamento e escoamento do petróleo. Sob a ótica logística, são volumes recebidos constantemente, ocupam grande espaço tanto no convés das embarcações, quanto na plataforma e precisam ser recebidos no prazo solicitado para que não haja parada não programada de produção motivada por falta de algum produto.

A Figura 2 mostra os tipos de refis que são utilizados em plataformas. Para segurança durante o transporte, eles são enviados em uma proteção metálica, a qual preserva o refil de um

possível impacto durante a sua movimentação. Os refis podem ter 5000 litros, com dimensão de 3,00 X 2.30 X 2,30m ou 1500 litros, com 1,20 X 1,40 X 1,80m.

Figura 2 – Refis de Produto Químico



Fonte: www.intersea.com.br e https://cargostore.com, acesso em 24.06.2020.

2.2. Previsão de Demandas

Para [Tubino 2009], a previsão tem uma função de destaque nos processos de planejamento dos sistemas de produção, pois permitem que os gestores tenham visão futura do processo e planejem adequadamente suas ações. [Makridakis et al. 1998] afirma que um modelo de previsão é dividido em cinco etapas, a saber:

1) Definição do problema;
2) Coleta de dados;
3) Análise exploratória preliminar;
4) Seleção do modelo apropriado;
5) Uso e avaliação do modelo de previsão.

Métodos quantitativos consistem em analisar os dados passados objetivamente, aplicando-se modelos matemáticos para projetar a demanda futura. Estas técnicas visam descrever o comportamento da demanda através do ajuste de um modelo que gere o menor erro possível [Tubino 2009].

Dentre os principais métodos utilizados, podemos citar: Médias Móvel e o Amortecimento Exponencial. A vantagem destes métodos é o fato deles servirem como ferramenta para o entendimento mais amplo da demanda, visto que buscam identificar e quantificar os principais fatores que a influenciam [Murdick e Georgoff 1993].

2.2.1. Média Móvel

O método de Média Móvel é utilizado pela sua facilidade de implementação e manutenção e pela necessidade de poucos dados históricos para a sua aplicação. É apropriado para previsões de curto prazo e para dados históricos irregulares, os quais não apresentem tendência ou sazonalidade [Makridakis et al. 1998].

[Makridakis et al. 1998] afirmam que a Média Móvel consiste numa técnica simples de suavização exponencial de dados históricos, a qual calcula a média aritmética ou ponderada das k observações mais recentes, desprezando-se a mais antiga e acrescentando a mais recente, conforme mostra a Equação (1):

$$M_t = M_{t-1} + \frac{Z_t - Z_{t-k}}{k} \qquad (1)$$

onde:
M_t: média móvel simples da demanda no período atual
M_{t-1}: média móvel simples da demanda no período anterior
Z_t: elemento da série temporal no instante t
Z_{t-k}: elemento da série temporal no instante $t-k$
k: comprimento da média

2.2.2. Modelo de Amortecimento Exponencial Simples

Segundo [Gaither e Frazier 2006], os métodos de Amortecimento Exponencial são métodos de ajuste de uma curva adequada aos dados históricos de uma determinada série temporal. Esta técnica fornece uma média exponencialmente ponderada, onde os pesos designados decrescem ao longo do tempo, ou seja, os dados mais recentes têm um peso maior.

Seja $\bar{Z}_t$ denominado o valor exponencialmente amortecido, podemos descrever um Modelo de Amortecimento Exponencial Simples como:

$$\bar{Z}_t = \bar{Z}_t + \alpha(1-\alpha)\bar{Z}_{t-1} + \alpha(1-\alpha)^2\bar{Z}_{t-2} + \cdots \quad (2)$$

onde:

α: constante de amortecimento

De acordo com [Morettin 2006], quanto menor for o valor de α utilizado, mais estáveis serão as previsões finais, pois desta forma, pesos maiores serão dados às observações passadas e, com isso, qualquer flutuação aleatória no presente exercerá um peso menor no cálculo da previsão.

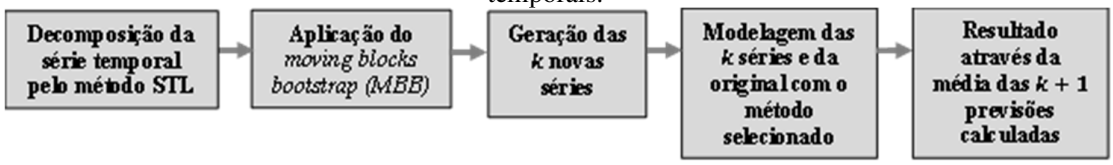
2.2.3. *Bagging*

Proposto por [Breiman 1996], o *Bagging (Bootstrap Aggregating*) é um método que tem por objetivo gerar múltiplas versões de preditores utilizando *Bootstrap*. Consiste em retirar k amostras de tamanho N com reposição, a partir do conjunto de dados originais e criar amostras *Bootstrap*. Isto significa que em cada amostra k, uma dada observação do conjunto original pode não aparecer, ou aparecer mais de uma vez. Em cada uma destas amostras, computa-se um preditor. O preditor final agrega os k preditores e a classe mais frequente é a escolhida [Rübesam 2004].

A aplicação do *Bagging* em previsões de séries temporais ainda é pouco observada, apesar do uso da técnica propiciar uma melhora substancial na capacidade preditiva de métodos como Regressão Linear e Árvores de Decisão [Dantas e Oliveira 2015].

Dentre os métodos utilizados para esta aplicação, pode destacar o *Bagging* com Amortecimento Exponencial Simples (*Bagging* ETS), proposto por [Bergmeir et al. 2014] e o *Bagging* ARIMA, utilizado por [Dantas e Oliveira 2015]. O procedimento para estas aplicações é semelhante e está ilustrado no fluxograma da Figura 3.

Figura 3 –Fluxograma do procedimento para aplicação do *Bagging* em previsão de séries temporais.



Fonte – Elaboração do autor, baseado em [Dantas e Oliveira 2015]

A decomposição da série temporal pelo método STL *(Seasonal Trend Decomposition using Loess)* foi desenvolvido por [Cleveland et al. 1990], decompõe a série temporal em três componentes aditivos: sazonalidade, tendência e *remainder,* sendo esta última a diferença entre as duas primeiras componentes e a série temporal.

A reamostragem por blocos (*moving blocks bootstrap*) foi formulada por [Künsch 1989] e [Liu et al. 1992], para aplicações em dados dependentes. Em contraste com a reamostragem de uma única observação de cada vez, esta técnica reamostra blocos de observações por vez. Como resultado, a estrutura dependente da observação original que é preservada dentro de cada bloco [Lahiri 2003].

O número de réplicas considerado necessário em estudo realizado por [Breiman 1996] varia entre 25 e 50 réplicas, o qual afirma que um número excessivo de replicações não aumenta a acurácia do resultado.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Neste artigo, será utilizado o método *Bagging* ETS, visto que a análise preliminar das séries históricas apontou o método de amortecimento exponencial como o mais adequado ao comportamento dos dados em questão.

2.2.4. Erros de Previsão

O erro de previsão é definido como:

$$e_t = Y_t - F_t \qquad (3)$$

onde:
Y_t: observação atual para um período t
F_t: previsão para o mesmo período

Comumente, F_t é calculada utilizando os dados $Y_{1,\dots,}\ Y_{t-1.}$ Podemos descrever e_t como o primeiro passo para o cálculo do erro de previsão, pois esta é apenas a diferença entre a observação Y_t e a previsão realizada utilizando todas as outras observações, mas não incluindo a Y_t.

A Tabela 1 mostra alguns tipos de cálculos de erros utilizados, os quais adequam-se a diferentes tipos de previsão.

Tabela 1 – Erros de previsão

Tipos de Erro	Equação
ME - erro médio (*mean error*)	$ME = \frac{1}{n}\sum_{t=1}^{n} e_t$ (4)
MAPE - erro médio absoluto percentual (*mean absolute percentage error*)	$MAPE = \frac{1}{n}\sum_{t=1}^{n} \frac{e_t}{Y_T}.100$ (5)
MAD - erro absoluto médio (*mean absolute deviation*	$MAD = \frac{1}{n}\sum_{t=1}^{n} \lvert e_t \rvert$ (6)

Fonte: Elaboração do autor

A equação 4, mostra o erro médio ME. Este cálculo indica se há previsão sistemática acima ou abaixo do esperado, o chamado viés da previsão. Ele retrata a razão entre o valor do erro acumulado e o tamanho da amostra.

O erro percentual absoluto médio MAPE (*mean absolute percentage error*), apresentado na equação 5, representa a média percentual da divisão entre erro de previsão e o valor real. O MAPE expressa a acurácia em porcentagem do erro. Por isso, torna-se mais fácil de ser entendido do que outra medida de acurácia. Entretanto, é válido examinar o gráfico da série para garantir que não haja valores iguais ou muito próximos a zero. Como o MAPE divide o erro absoluto pelo valor atual, valores próximos ou iguais a zero podem inflar bastante o MAPE [Kahn 1999].

A equação 6 mostra o erro absoluto médio MAD, o qual é a soma dos desvios absolutos dos períodos dividida pelo número de períodos. [Makridakis et al 1998] afirmam que este indicador é mais utilizado quando se pretende medir o erro da previsão na mesma unidade que a série original. [Fox 1981] corrobora esta informação, afirmando que o MAD é considerado preciso e robusto como medida da habilidade de modelos numéricos em reproduzir a realidade.

Conforme [Tubino 2009], um dos critérios para avaliação do método de previsão proposto é comparar o valor do módulo do erro acumulado ($|\sum ME|$) com o valor de 4 MAD. Quando o erro acumulado for maior, o problema deve ser identificado e o modelo deve ser revisto.

3. Metodologia

Este artigo foi desenvolvido através de pesquisa quantitativa aplicada, de caráter exploratório, pois visa gerar conhecimentos para aplicação prática, dirigidos à solução de problemas específicos, enfatizando a objetividade na coleta e análise dos dados numéricos, assim como a utilização da estatística nesta análise [Gil 2007].

Foram coletados dados acerca do número de refis de produtos químicos recebidos por uma plataforma de petróleo da Bacia de Campos, a partir do Sistema SAP, o qual é utilizado pela empresa como base de dados integrada. O período considerado foi entre janeiro de 2018 e julho de 2019, de cinco em cinco dias, que é a frequência de atendimento das embarcações às plataformas.

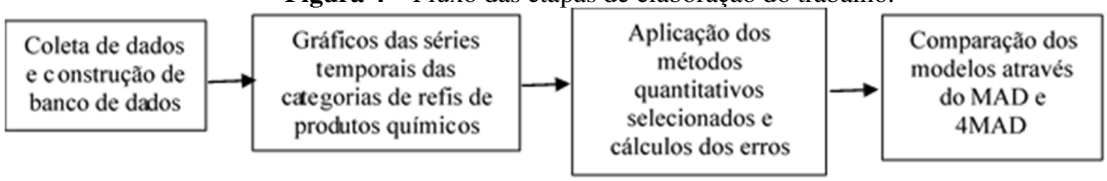
Como são utilizados dois tipos distintos de refil, estes foram denominados da seguinte forma:

REFIL PQ A: refil de 5000 litros, de dimensão 3,00 X 2,30 X 2,30m;

REFIL PQ B: refil de 1500 litros, de dimensão 1,20 X 1,40 X 1,80m;

Os dados de interesse foram organizados em planilhas eletrônicas e seguido o fluxo da Figura 4, que representa as etapas de elaboração do trabalho realizado.

Figura 4 – Fluxo das etapas de elaboração do trabalho.



Fonte: Elaboração do autor

Com o auxílio do *software* estatístico R, foram construídos os gráficos, realizados os testes estatísticos deste artigo, assim como realizados os métodos de previsão e o cálculo dos erros encontrados.

4. Resultados

Foram recebidos 1108 refis de produtos químicos pela plataforma entre janeiro de 2018 e junho de 2019, sendo 820 de REFIL PQ A e 288 de REFIL PQ B. Como as cargas são entregues de cinco em cinco dias, houve um total de 109 observações. As Figuras 5 e 6 representam o histórico de demanda das duas categorias ao longo do período estudado.

Figura 5 – Histórico de demanda da categoria REFIL PQ A.

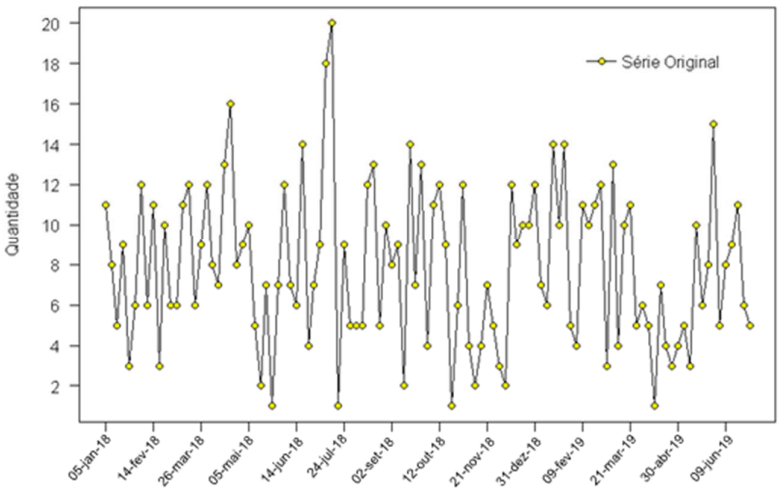
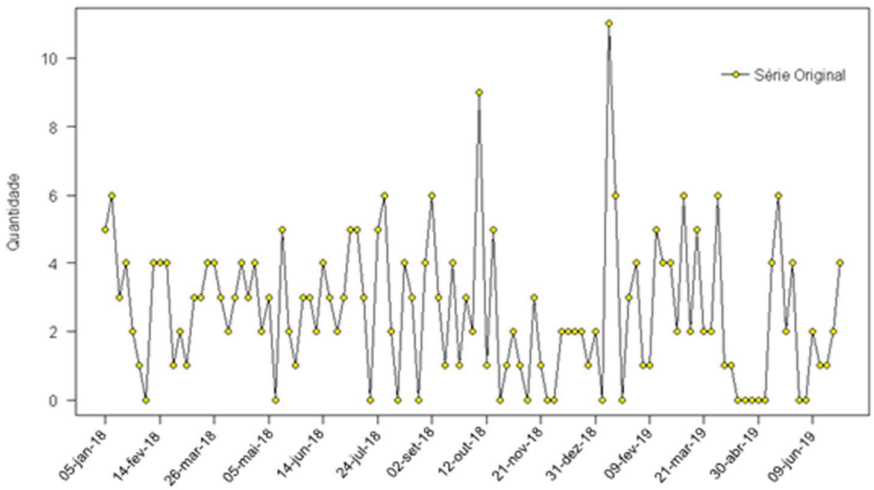
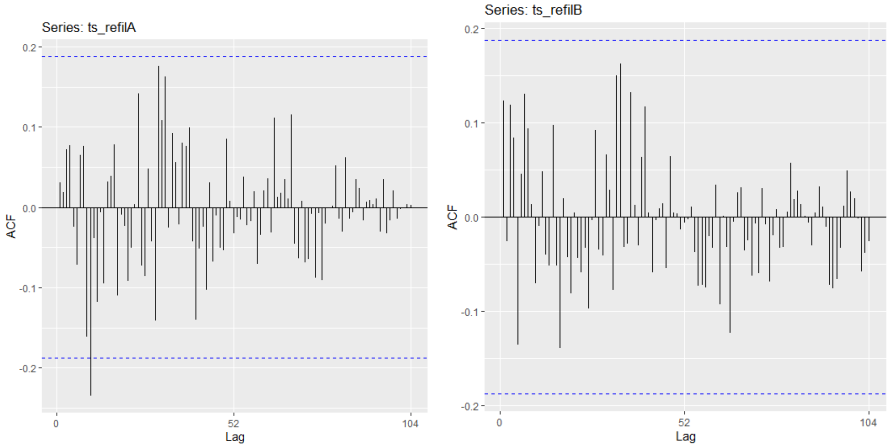


Figura 6 - Histórico de demanda da categoria REFIL PQ B



Seguindo a análise exploratória para caracterização dos dados históricos, foram avaliados os correlogramas dos dados históricos em estudo, os quais estão apresentados na Figura 7. Nota-se que há autocorrelação na série REFIL PQ A e isso não é observado na série REFIL PQ B. Além disso, ambos não apresentam decaimento leve, comprovando que não há tendência. Não é observada sazonalidade.

Figura 7 - Correlograma das séries históricas REFIL PQ A (a) e REFIL PQ B (b).



(a) (b)

Por último, foram aplicados os testes de estacionariedade e de normalidade. Para testar a estacionariedade, foi realizado o teste de raiz unitária de Dickey-Fuller Aumentado (ADF) e a normalidade foi testada através do teste de Jarque-Berra. A Tabela 2 mostra os resultados encontrados para cada conjunto de dados.

Tabela 2 – Resultados dos testes de estacionariedade e normalidade

	ADF	**Jarque-Bera**
	p-value	***p-value***
REFIL PQ A	$1{,}4.10^{-10}$	0,24
REFIL PQ B	$1{,}0.10^{-9}$	0,11

Observando os resultados do teste ADF, nota-se que o *p-value* encontrados são todos menores que o nível de significância de 0,05. Com isso, a hipótese nula H_0de que há pelo menos uma raiz unitária deve ser rejeitada e as séries são estacionárias.

Para o teste de Jarque-Bera, foram encontrados *p-value* maiores que 0,05, logo não há indício para rejeitar a H_0, ou seja, os dados apresentam distribuição normal.

Com base nos dados apresentados e nas características identificadas na análise exploratória dos dados, foram realizadas as previsões de demanda. Para a Média Móvel, foi utilizado o comprimento de média igual a 3, pois o tamanho dessa janela gerou o menor erro de previsão para as séries estudadas.

Para a modelagem de previsão de demanda através do Método de Amortecimento Exponencial Simples, os valores da constante de suavização α foram otimizados pelo *software*, a fim de atingir o menor erro possível.

Por último, com o objetivo de atingir maior acurácia, foi aplicado o *Bagging* ETS, onde o número de amostras gerados foi k=25 e o tamanho dos blocos (*block size*) igual a 2. Estes foram os parâmetros que forneceram o menor erro, de acordo com os testes realizados.

A Tabela 3 apresenta um comparativo entre os valores dos erros de previsão MAD, do critério 4MAD e do erro acumulado, com o objetivo de avaliar o desempenho e validade dos métodos de previsão empregados. Para que o método de previsão seja considerado válido, o erro acumulado deve ser menor que o valor de 4MAD.

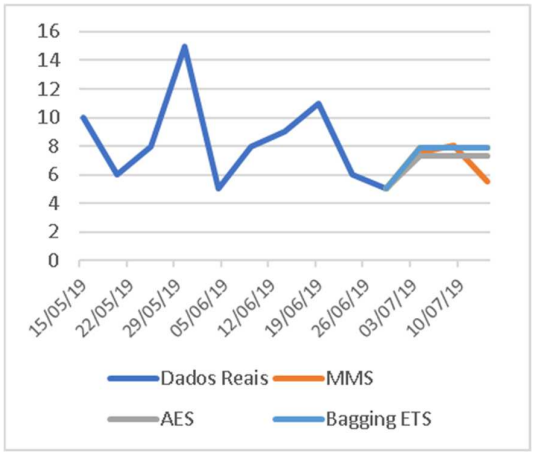
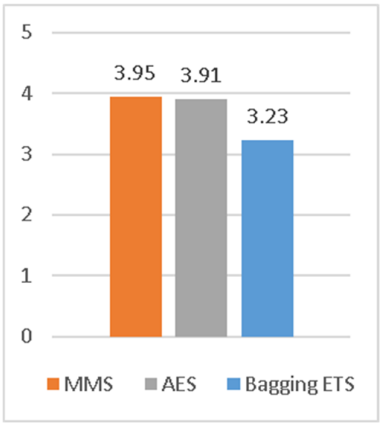
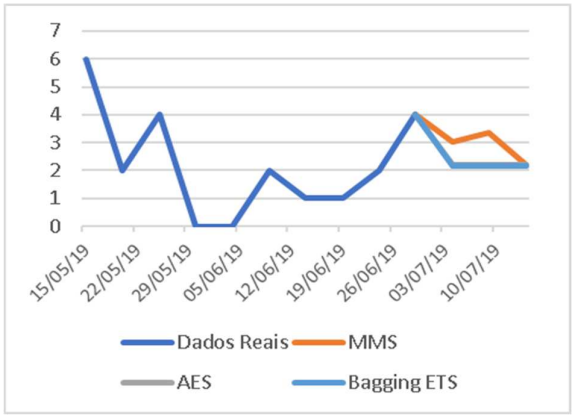
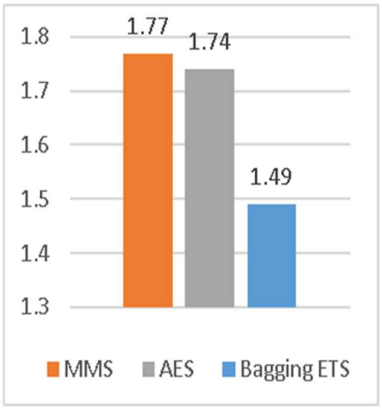
Tabela 3 – Comparação dos valores dos critérios de validação dos modelos

	Refil PQ A			**Refil PQ B**		
	Média Móvel	**Amort. Exp. Simples**	***Bagging* ETS**	**Média Móvel**	**Amort. Exp. Simples**	***Bagging* ETS**
MAD	3,95	3,91	3,23	1,77	1,74	1,36
4MAD	15,8	15,64	12,92	7,08	6,96	5,44
$\lvert\sum ME\rvert$)	1,33	3,63	9,81	2,33	2,53	0,39

Conclui-se que todos os métodos de previsão testados são válidos e podem ser utilizados para o planejamento da logística de envio e recebimento de refis de produtos químicos para uma plataforma de petróleo, visto que em nenhum dos métodos o valor limite de 4MAD foi excedido pelo erro acumulado.

A Tabela 4 reporta as previsões para os três próximos atendimentos marítimos, horizonte de previsão definido, e um gráfico comparativo dos valores de MAD encontrado para cada um deles. O horizonte de previsão, de 15 dias de antecedência, é equivalente ao praticado atualmente: é essa a antecedência que os profissionais de logística recebem a programação de cargas que será enviada à plataforma.

Tabela 4 - Comparativo entre a previsão de demanda e o indicador MAD para os métodos de previsão avaliados

CAT	Previsão de Demanda	MAD
REFIL PQ A		
REFIL PQ B		

Pode-se concluir que o método *Bagging ETS* possui vantagem aos métodos clássicos aplicados em ambas as categorias de refis de produtos químicos enviados a uma plataforma de petróleo. Os valores de MAD foram menores nas duas categorias estudadas utilizando-se a reamostragem *Bootstrap* associada ao método de Amortecimento Exponencial. Com a aplicação do *Bagging ETS*, foi possível reduzir o erro MAD em 17,5% para REFIL PQ A e 14,3% em REFIL PQ B.

Os resultados obtidos com a aplicação do método *Bagging* ETS não foram comparados com as previsões realizadas pela empresa, pois atualmente não é utlizado um método científico para tal, e sim métodos qualitativos de previsão, baseados na opinião de especialistas da área e decisões gerenciais com base na experiência passada, o que inviabiliza a comparação dos resultados.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

5. Considerações Finais

No presente artigo, foram aplicadas três métodos de previsão de séries temporais para duas séries de refis de produtos químicos enviados a uma plataforma de petróleo, através dos métodos de Média Móvel, Amortecimento Exponencial Simples e Bagging ETS, além do cálculo do erro MAD, do 4MAD e do erro acumulado para análises dos métodos propostos.

Pelos resultados obtidos, é possível afirmar que os métodos de previsão utilizados atendem ao critério 4MAD nas duas categorias analisadas. No entanto, o Bagging ETS mostra-se mais vantajoso, visto que produziu resultados com maior acurácia. Isso é comprovado através da redução do erro em MAD em 17,5% para REFIL PQ A e 14,3% em REFIL PQ B.

A previsão de demandas de cargas contribuirá para a melhor gestão do envio e recebimento dos refis de produto químico a uma plataforma de petróleo, o que possibilitará um melhor planejamento do espaço de recebimento dos materiais, otimizando o tempo de operação entre barco e plataforma. Além disso, torna-se possível contribuir com o planejamento logístico da empresa estudada, visto que atualmente são adotados apenas critérios qualitativos para essa previsão.

Como recomendação para futuros trabalhos, ressalta-se o estudo de outras técnicas de reamostragem, visando aumentar o grau de confiança das previsões elaboradas. Técnicas como o *Bootstrap* aplicado aos resíduos podem trazer benefícios aos modelos de previsão, reduzindo ainda mais o erro encontrado. Além disso, a implantação de um banco de dados automático que permita agilidade e confiabilidade na revisão periódica do modelo, visto que o fluxo de cargas é dinâmico e novos métodos podem ser empregados ao longo do tempo.

Referências

Bergmeir, C., Hyndman, R., Benítez, J. (2014). Bagging Exponential Smoothing Methods Using STL Decomposition and Box-Cox Transformation. *Working Paper* 11/14.

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. *Journal of Official Statistics* 6:3-73.

Efron, B. (1979). Bootstrap methods: another look at the Jackknife. *The Annals of Statistics*., 7, 1–26.

Dantas, T.M.; Oliveira, F.L.C. (2015). Bagging ARIMA para Previsão de Demanda de Transporte Aéreo. *ENEGEP*, Fortaleza.

Ferreira Filho, V.J.M. (2015). Gestão de Operações e Logística na Produção de Petróleo: Fundamentos, Metodologia e Métodos Quantitativos, 1ª edição. Editora Elsevier, São Paulo.

Fox, D. G. (1981). Judging Air Quality Model Performance. Bulletin of the American Meteorological Society, v. 62, p. 599- 609.

Gaither, N.; Frazier, G. (2001). Operations management. Ohio.

Gil, A.C. (2007). Como elaborar projetos de pesquisa. 4ª edição, Editora Atlas, São Paulo.

Kahn, K. B.; Mentzer, J. T.; Bienstock, C. C. (1999). Benchmarking Sales Forecasting Performance Measures. *Business Horizons*, Indiana University.

Künsch, H.R. (1989). The jackknife and the bootstrap for general stationary observations. *Annals of Statistics* 17(3):1217–1241.

Lahiri, S. N. (2003). Resampling Methods for Dependent Data. New York, Springer-Verlag.

Liu, Y.R.; Singh, K. (1992). Efficiency and Robustness in Resampling. *Annals of Statistics* 20(1):370–384,1992.

Lopes. P. H. M. Uma Solução para o Problema de Roteamento de Embarcações de Apoio "Offshore" através da Meta-heurística RTR. (2011). Dissertação (Mestrado em Engenharia Elétrica) – COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

Makridakis, S.; Wheelwright, S.; Hyndman, R. J. (1998). *Forecasting methods and applications*. Editora: John Wiley & Sons.

Morettin, P. A.; Tolói, C. M. C. (2006). Análise de Séries Temporais. 2ª ed. Edgard Blücher, São Paulo.

Murdick, R. G.; Georgoff, D. M. (1993). Forecasting: a System Approach. Technologial Forecasting and Social Change. v. 44, n. 1, p. 1-16.

Rübesam, A. (2004). Estimação Não-Paramétrica Aplicada a Problemas de Classificação via *Bagging e Boosting*. Dissertação de Mestrado, UNICAMP, Campinas-SP.

Tsoumakas, G.; Angelis, L.; Vlahavas, I. (2005) Selective fusion of heterogeneous classifiers. Intelligent Data Analysis, 9(6):511–525.

Tubino, D.F. (2009). Planejamento e Controle da Produção: teoria e prática. São Paulo.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings