



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:**
Limitações e possibilidades



PREVISÃO DE DEMANDA E CONSUMO DE CONTENTORES PARA INDÚSTRIA OFFSHORE

ISRAEL PAULISTA BRANDÃO – israelbrandao91@gmail.com
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO - PUC-RIO

IGOR TONA PERES – igor.peres@puc-rio.br
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO - PUC-RIO

PAULA MAÇAIRA – paulamacaira@puc-rio.br
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO - PUC-RIO

ÁREA: 2. - LOGÍSTICA

SUBÁREA: 2.1 - GESTÃO DA CADEIA DE SUPRIMENTOS

RESUMO: Este estudo visa prever com precisão a demanda e consumo de contentores na indústria offshore de petróleo e gás. Utilizando métodos univariados e análise de dados históricos em séries temporais. O objetivo é identificar padrões de demanda e consumo, correlações entre diferentes fatores que influenciam a demanda por contentores, e desenvolver modelos preditivos que utilizem dados históricos para prever futuras demandas, analisadas pelo menor erro médio percentual absoluto - MAPE. Os resultados mostraram que os contentores de um metro e três metros são os que apresentaram menor MAPE, sendo considerados os melhores para previsão. Por outro lado, os modelos de contentores de dois metros e seis metros apresentaram maior MAPE e são considerados os que necessitarão de maior atenção na gestão e no dimensionamento, pois são os mais utilizados na logística offshore. No entanto, há limitações, como a coleta de dados durante a pandemia da Covid-19 e a agregação dos dados em nível de companhia. Como pesquisa futura, sugere-se analisar séries temporais diárias ao longo de dois anos e explorar outras metodologias, como modelos sazonais e algoritmos de aprendizado de máquina e inteligência artificial. As conclusões desta análise podem ser aplicadas para otimização da gestão de estoque e logística, garantindo a disponibilidade adequada de contentores e reduzindo custos operacionais e consumo de contentores na indústria offshore.

PALAVRAS-CHAVES: MODELO DE PREVISÃO; SÉRIES TEMPORAIS;
CONTENTORES OFFSHORE; CONSUMO DE DEMANDA; CONTENTORES DE CARGA.

FORECASTING DEMAND AND CONSUMPTION OF CONTAINERS FOR THE OFFSHORE INDUSTRY

ABSTRACT: *ABSTRACT: This study aims to accurately predict the demand and consumption of containers in the offshore oil and gas industry. Using univariate methods and analysis of historical data in time series, the objective is to identify demand and consumption patterns, and correlations between different factors influencing container demand, and develop predictive models using historical data to forecast future needs, analyzed by the lowest mean absolute percentage error - MAPE. The results showed that one-meter and three-meter containers had the lowest MAPE and were considered the best for prediction. On the other hand, two-meter and six-meter container models had higher MAPE and required more attention in management and sizing as they are the most used in offshore logistics. However, there are limitations such as data collection during the Covid-19 pandemic and data aggregation at the company level. As future research, it is suggested to analyze daily time series over two years and explore other methodologies such as seasonal models and machine learning algorithms. The conclusions of this analysis can be applied to inventory optimization and logistics, ensuring adequate container availability, and reducing operational costs and consumption of containers in the offshore industry.*

KEYWORDS: FORECASTING MODEL; TIME SERIES; OFFSHORE CONTAINERS; DEMAND CONSUMPTION; CARGO CONTAINERS.

1. INTRODUÇÃO

Na indústria de petróleo, o segmento de Exploração e Produção (E&P) engloba a busca por novas reservas de petróleo, bem como as atividades de produção e tratamento de óleo e gás natural. Nesse segmento, grande parte dessas operações ocorre em ambiente offshore, ou seja, em alto-mar, necessitando de contentores para os transportes terrestre e marítimo. Por isso, as unidades de perfuração de poços, conhecidas como sondas, e as unidades de produção, chamadas de plataformas, são unidades marítimas de grande porte que passam a maior parte de suas vidas úteis sem retornar a um porto.

O estudo foi realizado junto à área de Logística de E&P de uma empresa de petróleo de grande porte, que atende a mais de 100 unidades marítimas, e transporta aproximadamente 30 mil itens de consumo por mês, por meio de contentores. Esses contentores são utilizados para o embarque e desembarque de cargas nas unidades localizadas nas bacias de Santos, Espírito Santo e Campos, na região sudeste, além das bacias localizadas nas regiões Norte e Nordeste, abrangendo também a Margem Equatorial. Além disso, também são atendidas as sondas e embarcações submarinas.

É importante destacar que a principal motivação deste estudo é a previsão da demanda dos contentores, com o objetivo de evitar a ocorrência de faltas. É fundamental ressaltar que esses contentores podem conter cargas críticas e emergenciais, cuja ausência pode prejudicar significativamente a produção de petróleo e resultar em perdas na cadeia produtiva. Portanto, é essencial garantir uma previsão precisa do fornecimento adequado dos contentores, visando evitar interrupções e manter a produção de petróleo em pleno funcionamento.

A gestão da frota de contentores para carga geral é um recurso crítico em operações logísticas, especialmente para empresas que dependem do transporte bimodal (terrestre e marítimo). Nesse sentido, o ambiente offshore depende da gestão eficiente para atender todas as complexidades do sistema e das unidades marítimas. Essa gestão envolve o planejamento, controle, monitoramento e previsibilidade da demanda de contentores, assegurando que eles estejam disponíveis onde e quando necessário para atender à demanda de transporte de carga. A eficiência da gestão da frota de contentores é essencial para evitar problemas como a escassez de contentores, que pode resultar em atrasos no transporte, ou o excesso de contentores, que pode gerar custos desnecessários de locação, armazenamento e manutenção. A previsão precisa da demanda de contentores permite uma melhor alocação dos recursos, otimizando o uso dos contentores e minimizando custos operacionais.

O objetivo deste trabalho é prever com precisão a demanda por contentores de diferentes tamanhos, a fim de otimizar a alocação de recursos, minimizar o excesso de estoque e evitar a falta de contentores. Seguem abaixo as principais questões da pesquisa:

- Identificar padrões e correlações entre diferentes fatores que influenciam a demanda por contentores
- Desenvolver modelos preditivos que utilizem dados históricos para prever futuras necessidades de contentores

A metodologia adotada no estudo envolve a análise de uma série temporal de dados históricos, coletados de janeiro de 2022 a maio de 2024, com frequência mensal. Esses dados foram disponibilizados por meio do uso do dispositivo GPS (sistema de posicionamento global), que é gerenciado pela ferramenta de controle, para análise e monitoramento dos contentores (AKI TAANILA, 2010). O GPS de contentores utiliza a tecnologia de posicionamento por satélite para rastrear e monitorar a localização dos contentores de transporte de carga, permitindo um planejamento operacional mais eficiente, monitoramento de segurança e fornecimento de informações em tempo real sobre a localização dos contentores aos clientes e parceiros e da operação (DE GOOIJER; HYNDMAN, 2006). Este estudo utilizou uma abordagem de método de modelos univariáveis, que enfatiza os dados recentes, facilitando a detecção de tendências e padrões sazonais (CHATFIELD, 2005; KHANDAKAR, 2008; STAMATIS, 2020; WASHINGTON et al., 2020).

A seção materiais e métodos fornece detalhes sobre o trabalho realizado e as abordagens utilizadas. Em seguida, a seção resultados destaca as análises, exibindo os gráficos e tabelas relevantes do estudo. Por fim, na seção de conclusão, são apresentados os achados na pesquisa e oferecidas orientações para pesquisas futuras e discutidas as implicações práticas dos resultados obtidos.

2. MATERIAIS E MÉTODOS

O método de amortecimento exponencial é uma técnica amplamente utilizada na previsão de séries temporais, permitindo estimar valores futuros com base em dados históricos. Essa abordagem é particularmente útil quando se lida com séries temporais que apresentam padrões de níveis, tendência e sazonalidade (MORAES; SOUZA; ENAMI, 2023).

O método de análise de série temporal atribui pesos aos dados históricos, priorizando as observações mais recentes. Dessa forma, é possível capturar tendências e padrões latentes nos

dados, possibilitando previsões para o futuro. No entanto, é fundamental avaliar a adequação desse método para cada conjunto de dados específico, considerando suas características e peculiaridades. (HYNDMAN; KHANDAKAR, 2008).

Esta abordagem flexível é eficaz para a previsão de séries temporais, fornecendo informações valiosas sobre tendências e comportamentos futuros. No entanto, é necessário ter cautela ao aplicar a suavização exponencial, considerando a qualidade dos dados históricos e a consistência desses padrões no longo do tempo. Ao fazer isso, as análises podem aproveitar plenamente o potencial dessa técnica e obter resultados confiáveis em suas análises e previsões (HONG et al., 2016).

A avaliação dos quatro modelos univariados - Naive, Média, Suavização Exponencial (SES) e Regressão Dinâmica é fundamental para aprimorar as previsões em análises estatísticas.

- **Modelo Naive:** é simples e assume que o valor futuro será igual ao último valor observado, sendo útil como referência para comparar a eficácia dos demais modelos (PALDINO et al., 2021).
- **Modelo Média:** calcula a média das observações históricas, fornecendo uma abordagem mais estável e menos suscetível a flutuações (HYNDMAN; KHANDAKAR, 2008; MATHEW; MURUGESAN, 2020).
- **Suavização Exponencial (SES):** atribui pesos decrescentes aos dados históricos, priorizando observações mais recentes, e é adequada para séries com tendência e sazonalidade (MORAES; SOUZA; ENAMI, 2023).
- **Modelo de Regressão Dinâmica:** leva em consideração a dependência entre a série temporal e outras séries relevantes, permitindo uma previsão mais precisa ao considerar as influências externas (GOUVEIA et al., 2011; MAIA; CRIBARI-NETO, 2006).
- **Erro Médio Percentual Absoluto (Mean Absolute Percentage Error (MAPE)):** é uma medida comumente utilizada para avaliar a precisão de modelos de previsão. Ele calcula a média dos percentuais absolutos das diferenças entre os valores previstos e os valores reais, em relação aos valores reais. Essa métrica é expressa em forma de porcentagem e fornece uma indicação da magnitude do

erro em relação ao tamanho da variável em estudo (CHICCO; WARRENS; JURMAN, 2021; DE MYTTENAERE et al., 2016).

As avaliações dos modelos permitem selecionar o mais apropriado para cada conjunto de dados, considerando suas características e padrões específicos, resultando em previsões mais acuradas e informações valiosas para as tomadas de decisão. Após a avaliação, foi escolhido o modelo SES para seguir com as previsões dos modelos de contentores, por ser considerado a premissa do menor MAPE (AKI TAANILA, 2010; KIHORO; OTIENO; WAFULA, 2006).


No estudo, foram realizadas análises estatísticas e testes para avaliar o desempenho e a adequação do modelo de previsão de demanda. Essa abordagem permitiu uma avaliação abrangente e precisa da eficácia do modelo. Foram aplicadas medidas estatísticas relevantes, como o Erro Médio Percentual Absoluto (MAPE), e Coeficiente de Determinação (R^2), para avaliar a precisão das previsões (KIHORO; OTIENO; WAFULA, 2006; SCHLITTGEN, 1997).

Além disso, testes de diagnóstico foram realizados para verificar a adequação do modelo aos dados, como o teste de normalidade dos resíduos e o teste de autocorrelação. Todos os cálculos e análises foram realizados no software estatístico R, versão 4.4.0, que é amplamente utilizado e reconhecido na área. A seguir, serão apresentados os resultados obtidos, que fornecem insights valiosos sobre a eficácia do modelo de previsão de demanda e contribuíram para embasar decisões estratégicas no contexto estudado (AKI TAANILA, 2010; CHATFIELD, 2016; WASHINGTON et al., 2020).

3. RESULTADOS

Foram realizadas análises descritivas e a verificação dos outliers dos dados, e não foram identificados dados nulos e discrepantes em observações da série temporal. Alguns dos resultados obtidos são demonstrados nas figuras apresentadas no desenvolvimento da pesquisa:


Figura 1 - apresenta um gráfico que representa a demanda mensal de itens em contentores.



Fonte: O autor (2024).

No gráfico de itens demandados, observa-se um aumento significativo na demanda pós-COVID-19, até o final de 2022. A partir desse ponto, a demanda por itens começou a cair, o que pode ser atribuído à regularização da repressão de demanda causada pela complexidade da pandemia de 2019. Entre o segundo semestre de 2023 e 2024, a demanda mostrou oscilações, mas permaneceu estável, sem grandes aumentos ou reduções.


Figura 2 - mostra um gráfico que representa o consumo médio mensal de contentores.



Fonte: O autor (2024).

No consumo médio de contentores, foi identificado um padrão de oscilação na demanda por itens em contentores. No final de 2023, observou-se uma redução no consumo de contentores, indicando uma diminuição na demanda por cargas de pequeno porte.


Figura 3- mostra um gráfico que representa o uso mensal de contentores de um metro.



Fonte: O autor (2024).

O contentor de 1 metro, utilizado para o embarque de cargas de pequeno porte, apresenta uma oscilação natural na demanda devido ao seu porte e à variabilidade das necessidades do uso, tornando a previsão e a análise desafiadoras. Em 2022, foi identificado um pico de demanda e consumo deste modelo, chamado de itens de preparação. No entanto, a partir de 2023, a demanda começou a cair. Com a recuperação pós-pandemia, houve um leve aumento na demanda, que se manteve com oscilações naturais até 2024.


Figura 4- mostra um gráfico que representa o uso mensal de contentores de dois metros.



Fonte: O autor (2024).

O contentor de dois metros é um dos mais importantes nesta previsão, sendo amplamente utilizado. Em 2022, a demanda por esse tipo de contentor foi maior, mas posteriormente houve uma oscilação com tendência de queda. No entanto, o uso dos contentores de dois metros não oscilou na mesma medida que a demanda. Em 2024, houve uma queda natural no uso desses contentores, que está relacionada tanto ao porte quanto à redução da demanda.


Figura 5 - mostra um gráfico que representa o uso mensal de contentores de três metros.



Fonte: O autor (2024).

No caso do contentor de três metros, houve uma oscilação na demanda em 2022, inicialmente com uma queda devido às flutuações causadas pela pandemia. Posteriormente, houve um aumento na demanda, seguido por variações até 2024, caracterizadas por uma oscilação geral de queda na demanda e no porte da carga.

Figura 6- mostra um gráfico que representa o uso mensal de contentores de seis metros.




Fonte: O autor (2024).

No modelo de contentor de seis metros, é possível observar uma oscilação na demanda no início de 2022, seguida por uma queda. Essa variação pode ser atribuída à sua característica de ser um contentor de maior porte e peso. Além disso, há a possibilidade de restrições relacionadas às condições de mar, como ondas, que podem afetar as movimentações no segundo semestre do ano. Em 2023, foi identificado na figura uma queda normal na demanda, enquanto em 2024 mostra uma redução ainda maior. Essa redução pode ser explicada pelo rearranjo da carga e por controles operacionais implementados. Esses dados sugerem a importância de considerar diversos fatores ao analisar a demanda por contentores de seis metros, levando em conta tanto suas características físicas quanto o contexto operacional.

Figura 7- mostra um gráfico que representa a FAC autocorrelação dos itens demandados.

FAC- série temporal alvo - itens Demandados




Fonte: O autor (2024).

Lag um: A forte autocorrelação no lag um indica que a série possui uma memória curta, onde o valor atual é fortemente influenciado pelo valor anterior. Esse padrão é comum em séries com tendências ou componentes autorregressivos.

Lag dois: A correlação significativa no lag dois pode sugerir um padrão repetitivo ou sazonal, indicando que eventos ou valores observados têm uma influência persistente que se estende por pelo menos dois períodos.


Figura 8- mostra um gráfico que representa regressão dinâmica residual.



Fonte: O autor (2024).

Após correlacionar e realizar a regressão dinâmica com as variáveis dos modelos de contentores e itens demandados, todas se mostraram significativas, indicando que conseguimos um modelo adequado. O R^2 ajustado médio é 47,77 %. Além disso, ao analisar a função de autocorrelação (FAC) nos resíduos, não encontramos lags significativos, o que sugere que não há estrutura residual nos dados.

Figura 9 - mostra um gráfico MAPE - Erro Médio Percentual Absoluto.



Fonte: O autor (2024).

Avaliamos quatros modelos para previsão - Naive, Média e Suavização Exponencial (SES), além de incorporar o modelo de autocorrelação cruzada. Calculamos o MAPE para cada modelo. Após uma análise cuidadosa, optamos pelo modelo de Suavização Exponencial, devido ao seu menor MAPE, escolhendo-o para as previsões futuras.


4. CONCLUSÕES

O estudo concluiu que é possível prever o uso e consumo de contentores no setor de petróleo e gás offshore. Foi desenvolvido um modelo de previsão utilizando o método de amortecimento exponencial. Os resultados desses modelos estão representados no gráfico de MAPE, com medidas de comparação aplicadas para avaliar seu desempenho. Observou-se que a demanda por contentores de um metro e três metros, com um atraso de um período, é um preditor significativo da demanda de itens, destacando a importância desses tamanhos de contentores na previsão.

As conclusões desta análise podem ser aplicadas para otimizar a gestão de estoque e logística, garantindo a disponibilidade adequada de contentores e reduzindo custos

operacionais.

Figura 10- mostra um gráfico de previsão de demanda contentor um metro



Fonte: O autor (2024).

Figura 11- mostra um gráfico de previsão de demanda contentor três metros




Tabela 1- mostra os cenários e modelos e os MAPE dos das previsões.

Cenário	modelos	Variáveis exploratória	Mape
1 - Teste	Naive	Itens Demandandos	9,01%
2 - Teste	Média	Itens Demandandos	20,08%
3 - Teste	Suavização(ETS)	Itens Demandandos	8,40%
4 - Teste	Regressão dinâmica	Itens Demandandos	14,61%
5 - Teste	Suavização(ETS)	Contentor 1M	2,84%
6 - Teste	Suavização(ETS)	Contentor 2M	18,34%
7 - Teste	Suavização(ETS)	Contentor 3M	6,94%
8 - Teste	Suavização(ETS)	Contentor 6M	17,61%

Fonte: O autor (2024).

Em relação à planilha e aos MAPEs, observamos que o teste da variável itens demandados resultou em 8,40%, o que foi escolhido para avançar com outras variáveis nos modelos dos contentores. O contentor de um metro apresentou o menor MAPE, sendo amplamente utilizado e com previsão bem ajustada ao consumo e às operações logísticas offshore. O contentor de três metros teve o segundo menor MAPE, destacando-se pelo bom uso constante e como substituto frequente quando outros modelos estão indisponíveis.

O contentor de seis metros teve o penúltimo MAPE, mostrando bom uso, mas com previsão um pouco mais ajustada ao erro, sendo preferencialmente utilizado como última substituição devido ao seu peso, volume e tamanho da carga. Por outro lado, o contentor de dois metros, sendo o mais utilizado, apresentou o MAPE mais elevado, devido à complexidade na previsão, refletindo sua alta demanda e as dificuldades associadas à sua substituição, exigindo um cuidado especial no dimensionamento e na contratação para fluidez da operação.

Para pesquisas futuras, há oportunidades de aprimoramento no estudo da previsão da demanda e consumo de contentores na indústria offshore.

Uma abordagem interessante seria analisar a série temporal por dia durante um período de dois anos, permitindo uma compreensão mais detalhada dos padrões diários de demanda e consumo. Isso possibilitaria identificar variações sazonais, tendências de curto prazo e comportamentos específicos de cada dia da semana.

Além disso, explorar outras metodologias, como modelos de séries temporais sazonais, algoritmos de aprendizado de máquina, análise de dados multivariados, modelos de simulação e técnicas de inteligência artificial, poderia melhorar a precisão e eficiência dos modelos de previsão, aprimorando a gestão de contentores e reduzindo custos operacionais.

Os resultados obtidos oferecem relevantes achados sobre a natureza dos dados utilizados neste estudo. Por um lado, é possível que haja tendência ou sazonalidade nos dados, o que pode ser atribuído à alta volatilidade e imprevisibilidade da demanda durante a pandemia da Covid-19, bem como à agregação das informações, o que pode ter ocultado padrões mais sutis. Essas limitações do estudo apontam para a necessidade de uma análise mais aprofundada

e o uso de dados mais detalhados e precisos, de modo a obter uma compreensão mais abrangente da demanda e consumo de contentores na indústria offshore.

REFERÊNCIAS

- AKI TAANILA. **Time series forecasting 1 Time series forecasting**. [s.l: s.n.]. v. 33
- CHATFIELD, C. Time-series forecasting. **Significance**, v. 2, n. 3, 2005.
- CHATFIELD, C. **The analysis of time series: An introduction, sixth edition**. [s.l: s.n.].
- CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, v. 7, 2021.
- DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, v. 22, n. 3, 2006.
- DE MYTTENAERE, A. et al. Mean Absolute Percentage Error for regression models. **Neurocomputing**, v. 192, 2016.
- GOUVEIA, C. et al. **Regressão Dinâmica aplicada à análise da classificação de custos : estudo empírico em uma empresa do setor hoteleiro**. XVIII Congresso Brasileiro de Custos. **Anais...**2011.
- HONG, T. et al. **Probabilistic energy forecasting: Global Energy Forecasting Competition 2014 and beyond**. **International Journal of Forecasting**, 2016.
- HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, v. 27, n. 3, 2008.
- KIHORO, J.; OTIENO, R.; WAFULA, C. Seasonal time series forecasting: a comparative study of arima and ann models. **African Journal of Science and Technology**, v. 5, n. 2, 2006.
- MAIA, A. L. S.; CRIBARI-NETO, F. Dinâmica inflacionária brasileira: Resultados de auto-regressão quantílica. **Revista Brasileira de Economia**, v. 60, n. 2, 2006.
- MATHEW, S.; MURUGESAN, R. Indian natural rubber price forecast-an autoregressive integrated moving average (ARIMA) approach. **Indian Journal of Agricultural Sciences**, v. 90, n. 2, 2020.
- MORAES, F. S.; SOUZA, B. G. DE; ENAMI, L. M. Aplicação da suavização exponencial para previsão de demanda de uma estamperia de canecas de pequeno porte. **Brazilian Journal of Production Engineering**, v. 9, n. 5, 2023.
- PALDINO, G. M. et al. Does AutoML Outperform Naive Forecasting? †. **Engineering Proceedings**, v. 5, n. 1, 2021.
- SCHLITTGEN, R. CHRIS CHATFIELD: The Analysis of Time Series. An Introduction. 5th edition, VII + 283 pp. Chapman & Hall 1996, £ 18.99 (paperback). **Biometrical Journal**, v. 39, n. 4, 1997.
- STAMATIS, D. H. Time Series and Forecasting. Em: **Six Sigma and Beyond**. [s.l: s.n.].
- WASHINGTON, S. et al. Forecasting in Time Series. Em: **Statistical and Econometric Methods for Transportation Data Analysis**. [s.l: s.n.].