

A utilização de Redes Neurais Artificiais para a previsão da demanda de combustíveis na Marinha do Brasil

Autoria: C-ApA-IM 2023 - DAbM - 04

RESUMO

Este trabalho investiga a viabilidade de otimização da previsão de demanda de combustíveis na Marinha do Brasil por meio do uso de Redes Neurais Artificiais (RNA). O estudo focou no desenvolvimento de um modelo computacional que prediz com acurácia a necessidade desses recursos. Concentra-se exclusivamente em combustíveis, pela sua preponderância nos gastos institucionais, e explora dados do Sistema de Informações Gerenciais do Abastecimento. Para alcançar a implementação do modelo, o trabalho propõe a análise classificatória da demanda, uma análise exploratória dos dados, a construção de um modelo preditivo via RNA e sua validação por meio de simulações. O estudo é inovador pela aplicação de RNA na previsão de abastecimento de combustível na Marinha, podendo significar um salto qualitativo na precisão logística e na tomada de decisões informadas.

Palavras-chave: Redes Neurais Artificiais, Previsão de Demanda, Marinha do Brasil, Abastecimento de Combustíveis.

1 INTRODUÇÃO

A gestão do abastecimento na Marinha do Brasil (MB) é realizada por um componente do Sistema de Apoio Logístico chamado Sistema de Abastecimento da Marinha (SAbM). Este sistema é delineado como uma entidade composta por órgãos, processos e recursos, todos interconectados e interdependentes. Sua concepção visa garantir, sustentar e supervisionar o fornecimento dos materiais indispensáveis para manter as Organizações Militares (OM) operando em condição de plena eficiência (BRASIL, 2020).

O SAbM desempenha o papel crucial de fornecer uma variedade de categorias de materiais, incluindo material comum, gêneros, sobressalentes para navios, armamentos, material de saúde, combustíveis, lubrificantes e graxas, veículos e uniformes (BENTES, 2019).

No contexto contemporâneo, a eficiência do Abastecimento é essencial para a MB, que desempenha um papel crucial na defesa do país. A gestão eficaz dos recursos é vital para manter a prontidão operacional. Nesse cenário, a pesquisa sobre a utilização de tecnologias avançadas, como as RNA, para prever a demanda de combustíveis, emerge como um campo de estudo fundamental e relevante.

Para corroborar essa afirmação Carvalho (2018), destaca que previsão de demanda representa o início do processo logístico, envolvendo a análise preditiva do consumo. A importância dessa área é crítica para o funcionamento fluido das fases seguintes na cadeia logística, possibilitando um controle de estoques mais eficaz e evitando custos desnecessários causados tanto pelo excesso quanto pela falta de inventário. Reconhecendo que todos os modelos de previsão possuem suas limitações, a seleção cuidadosa de uma ferramenta adequada empodera os gestores a atenderem de forma mais assertiva às necessidades reais dos clientes, reduzindo os obstáculos potenciais.

Assim como Carvalho (2018) afirma, Bluvol (2022) enfatiza em sua dissertação que nenhuma metodologia é à prova de falhas, e eventos imprevistos de grande magnitude podem surgir inesperadamente. No entanto, a aplicação de algoritmos é fundamental para auxiliar a estruturação das decisões de forma mais acurada, eliminando tendências emocionais e favorecendo decisões mais sólidas e lógicas.

Pellegrini e Fogliatto (2001) ressaltam que métodos de previsão viabilizam a formulação de modelos matemáticos fundamentados em dados existentes, oferecendo previsões mais exatas do que as baseadas meramente em intuição. Por outro lado, Werner, Lemos e Daudt (2006) alertam que previsões imprecisas podem trazer complicações para a organização ao não satisfazer a demanda, uma situação de subestimação, ou ao resultar em um acúmulo desnecessário de produtos acabados, indicando uma superestimação.

Através do programa Publish or Perish e com a utilização do Google Acadêmico como recurso informativo, identificamos uma série de estudos focados na previsão de demanda na Marinha do Brasil, empregando termos como "previsão de demanda" e "Marinha do Brasil". Notavelmente, diversos trabalhos que abordam este tópico na Marinha do Brasil (CARVALHO, 2018; MELLO; CARDOSO; PESSANHA, 2021; DOS SANTOS, 2016; FERREIRA, 2012) foram destacados e relevantes para este estudo.

Contudo, uma busca mais específica sobre a previsão de demanda usando RNA no contexto da MB revelou um vácuo na pesquisa existente. Esta falta de estudos destaca uma deficiência no conhecimento existente, salientando a necessidade de uma pesquisa mais detalhada para compreensão desse tema no âmbito acadêmico. A lacuna na pesquisa existente resalta a importância da realização desta pesquisa de modo a preencher a lacuna de conhecimento e proporcionar insights para a prática e pesquisas futuras sobre previsão de demanda na MB.

Diante do exposto, traçou-se como objetivo responder ao seguinte problema de pesquisa: A previsão da demanda de Combustíveis, Lubrificantes e Graxa (CLG) na Marinha do Brasil pode ser otimizada com a utilização de Redes Neurais Artificiais (RNA)? E para responder, definiu-se como objetivo geral implementar um sistema computacional que possa ser utilizado para prever a demanda de CLG na Marinha do Brasil.

Para concretizar este objetivo geral, estabeleceram-se os seguintes objetivos específicos: i) analisar a classificação da demanda de CLG a partir dos dados de fornecimento; ii) realizar a análise exploratória de dados; iii) desenvolver um modelo utilizando Redes Neurais Artificiais que realize as previsões de demanda de CLG; e iv) realizar treinamento e testes para validar a eficácia do modelo proposto.

Este estudo foca somente em combustíveis, motivado tanto por restrições de tempo quanto pela complexidade de incorporar uma variedade ampla de lubrificantes e graxas. Além disso, os combustíveis representam a maior parcela dos gastos com CLG. Tais combustíveis incluem Gasolina Comum, Óleo Diesel Marítimo, Óleo Diesel Especial MB, Óleo Diesel Rodoviário, e Querosene de Aviação do tipo QAV-1 e QAV-5, sendo o último exclusivo para abastecimento de aeronaves em navios. Tal foco permite uma análise mais detalhada e direcionada.

Após esta introdução, a base teórica será apresentada em seguida na segunda seção, sendo essencial para os conceitos em foco. A terceira seção detalha a metodologia empregada na pesquisa, descrevendo as técnicas empregadas. Segue-se com a apresentação dos resultados alcançados. E finalmente, discute-se a análise dos resultados obtidos e uma reflexão conclusiva sobre o estudo.

2 REFERENCIAL TEÓRICO

2.1 Previsão de Demanda

Conforme Carvalho (2018), prever a demanda é crucial para uma gestão de inventário eficaz. Como explicado por Gerber et. Al (2013), ao afirmar que prever a demanda é o ponto de partida essencial para planejar atividades, como a gestão do fluxo de caixa e o planejamento de produção, essa prática é mais comum em empresas que lidam com bens de consumo. Para reforçar essa ideia Makridakis e Hibon (2000), afirmam que prever a demanda é fator decisivo para, entre outras finalidades, minimizar despesas e oferecer um serviço de qualidade superior.

Petrônio e Laugeni (2005) apontam que antecipar as necessidades de demanda é crucial para o uso eficiente dos equipamentos, garantindo a reposição pontual e exata de materiais, bem como o planejamento apropriado de todas as atividades vitais no processo de produção.

Orquestrar a cadeia de suprimentos, abrangendo desde a obtenção de matérias-primas até a entrega dos produtos ou serviços finais aos clientes, emerge como um dos enigmas mais complexos no cenário corporativo atual. Paralelamente, a destreza em prever com acurácia a futura procura por produtos ou serviços ofertados pela empresa é uma habilidade igualmente desafiadora e intrincada. Em outras palavras, é um verdadeiro desafio antecipar as quantidades que o mercado absorverá e, por conseguinte, que serão produzidas pela empresa (DA SILVA, 2020).

Entretanto, prever a demanda não é um processo isento de falhas. À medida que nos afastamos no tempo, a probabilidade de precisão na previsão diminui. É crucial não apenas coletar informações cuidadosamente, mas também selecionar a técnica de previsão de forma criteriosa. Exige-se uma abordagem lógica e ponderada para discernir, entre os métodos já existentes, qual se encaixa melhor na situação específica (BALLOU, 2009).

Técnicas quantitativas, qualitativas, ou uma combinação entre ambas são utilizadas para forjar as previsões de demanda. Os métodos quantitativos ou técnicas de previsão, se apoiam na análise de séries temporais, dados que delineiam as oscilações na demanda ao longo do tempo. Dentre tais métodos, destacam-se a decomposição de séries temporais, o alisamento exponencial, a metodologia de Box-Jenkins, e a implementação de redes neurais (ARMSTRONG, 2001).

Ritzman e Krajewski (2003) destacam a importância de escolher com precisão a técnica de previsão apropriada, sublinhando que, em determinadas circunstâncias, é essencial buscar um ponto de equilíbrio entre a exatidão da previsão e os custos a ela relacionados. O alvo principal é desenvolver uma abordagem de previsão que se molde perfeitamente às nuances específicas da demanda. Além disso, ao escolher a técnica, torna-se primordial ponderar sobre o alcance temporal das projeções, isto é, se são a curto, médio ou longo prazo.

Conforme Moreira (2008) aponta, apesar da variedade de métodos de previsão, eles tendem a compartilhar um traço comum: o comportamento passado molda as expectativas futuras. Em outras palavras, as previsões, de algum modo, sempre incorporam as lições aprendidas com experiências anteriores. Ademais, é crucial reconhecer que os resultados das previsões não são infalíveis, visto que o grau de erro associado geralmente aumenta proporcionalmente à extensão do horizonte de previsão.

2.2 Classificação da Demanda

Syntetos et al. (2005) afirmam que a escolha do método de previsão de demanda torna-se mais simples quando a demanda é categorizada. Se um item é demandado em todos os períodos e mantém uma quantidade razoavelmente constante, a previsão não apresentará desafios significativos (SYNTETOS, 2001).

Também Syntetos et al. (2005), define quatro categorias distintas utilizadas para definir a demanda de cada item: i) Itens Regulares, caracterizados por variações quantitativas de fornecimento mínimas mas com um fornecimento constante ao longo do tempo; ii) Itens Intermitentes, marcados por variações quantitativas baixas e intervalos nos quais a demanda é quase nula; iii) Itens Erráticos, distintos por variações quantitativas elevadas e um volume de fornecimento considerável, resultando em uma demanda volátil e imprevisível; e iv) Itens Irregulares, com variações quantitativas significativas e frequentes lapsos de demanda, o que leva a um padrão de demanda complexo e desafiador de antecipar.

Para calcular essa classificação, utiliza-se o cálculo através das fórmulas dos Intervalos Médios entre Demandas (ADI – Average Demand Interval) e o Coeficiente de Variação (CV), como demonstrado em seguida (DOS SANTOS, 2018):

Intervalo médio entre as demandas (ADI):


$$ADI = \frac{qtd. de períodos sem demanda}{qtd. de períodos com demanda}$$

Coeficiente de variação (CV):

$$CV = \frac{Desvio Padrão}{Média dos Dados}$$

A partir dos dados do Intervalo Médio entre as Demandas (ADI) e do Coeficiente de Variação (CV), é possível determinar a categoria na qual um produto se enquadra, como ilustrado na Figura 1 a seguir (DOS SANTOS, 2018).

Figura 1 – Classificação de demanda



Fonte: Adaptado de Syntetos et. Al (2005)

2.3 Métodos de previsão de demanda

As abordagens de previsão de demanda, conforme delineadas por Makridakis, Wheelwright e Hyndman (1998) e Hanke (2001), se dividem entre métodos qualitativos e quantitativos. Na vertente qualitativa, a previsão se baseia puramente no discernimento humano, sem a manipulação direta de dados. No entanto, vale ressaltar que até essas avaliações subjetivas são, de alguma forma, moldadas pela percepção dos dados históricos. Em contrapartida, as abordagens quantitativas dispensam julgamentos subjetivos, baseando-se em processos automatizados que culminam em resultados numéricos. É interessante notar, conforme salientado por Hanke (2001), que alguns métodos quantitativos requerem manipulações de dados mais elaboradas que outros.

Dias (1999) observa que, embora os modelos qualitativos proporcionem um vislumbre da realidade, confiar unicamente neles pode gerar imprecisões nas previsões de demanda. De maneira similar, Makridakis et al. (1998) evidenciam que aqueles menos versados em previsão de demanda podem não valorizar devidamente o uso de informações históricas. Contudo, uma investigação minuciosa dos dados e do método revela que, apesar de não serem uma repetição exata, certos padrões tendem a se manifestar no futuro.

As técnicas qualitativas de previsão de demanda, pautadas em avaliações subjetivas e estimativas, frequentemente se apoiam em amostras reduzidas de especialistas do setor. Esses métodos pressupõem que os padrões passados podem não se repetir no futuro. As estimativas qualitativas se baseiam em uma gama de fatores pertinentes, o que as distingue das quantitativas, que se valem de funções matemáticas para modelar a demanda (DAVIS et al., 2001; MATTOS, 2004).

Higuchi (2006) salienta a necessidade de uma análise objetiva e minuciosa dos dados históricos, de modo a esboçar previsões embasadas em modelos matemáticos sólidos. Por outro lado, Garcia (2011) destaca a variedade de táticas abrangidas por tais métodos, que se estendem desde procedimentos elementares de cálculos até abordagens mais sofisticadas e intrincadas, demandando um domínio avançado em estatística e matemática computacional. Exemplos notáveis incluem o Modelo Autorregressivo de Média Móvel (ARIMA) e modelos que utilizam Redes Neurais Artificiais (RNA).

Os métodos quantitativos estão firmemente atrelados a dados numéricos confiáveis, sendo habilmente modelados por meio de fórmulas matemáticas intrincadas e complexas. Contrastando assim, com os modelos qualitativos que se baseiam em julgamentos subjetivos e estimativas aproximadas. E para a escolha do método mais adequado, algumas variáveis são observadas, como a essência dos dados disponíveis, os alvos precisos da análise, a amplitude do horizonte de tempo abrangido pela previsão e o nível de detalhes necessários para a pesquisa (FERREIRA, 2006). No entanto, é crucial manter a consciência da teia densa de complexidades que envolve a tomada de decisões baseadas exclusivamente em métodos quantitativos, um aspecto enfatizado por Rosselló et al. (2005).

2.4 Séries Temporais

Antes de 1925, as irregularidades nas séries temporais eram vistas como erros comparáveis às imprecisões de observação, sendo tratadas como distúrbios sistêmicos, análogos ao ruído para engenheiros eletrônicos. Fenômenos complexos, como os ciclos comerciais do século XIX, eram analisados com técnicas tradicionais, como a análise de Fourier, considerando-os como uma mistura de oscilações

harmônicas. Em 1927, Udny Yule revolucionou o campo ao estudar explosões solares, percebendo a irregularidade tanto nas amplitudes quanto nos intervalos entre picos e vales. Esse insight foi um marco no desenvolvimento de técnicas especializadas para análise de séries temporais, alterando radicalmente a compreensão e o estudo desses dados (GAIT, 1975).

Lunardi (2008) define as séries temporais como a análise de sequências de dados coletados ao longo do tempo, evidenciando relações com eventos passados. Essa técnica encontra aplicação em diversas áreas, como nos mercados financeiros, registros de eletrocardiogramas, previsões meteorológicas, entre outras. Sua utilização para detecção de intrusões é considerada uma abordagem inovadora. Contudo, como em qualquer experimento científico, os resultados podem divergir das expectativas iniciais.

A previsão de séries temporais é fundamental, dado que tais séries são encontradas em diversos contextos naturais, como na geofísica, astrofísica e meteorologia. Além disso, também possui aplicabilidade nas ciências sociais, médicas, econômicas e diversas áreas da engenharia, incluindo tratamento e transmissão de sinais e sistemas dinâmicos (DE CASTRO, 2001).

Downing e Clark (2006) explicam que as séries temporais, também chamadas de históricas, são conjuntos de dados que representam a mesma variável em períodos consecutivos. São sequências de valores de uma variável específica observados em intervalos de tempo regulares, com o tempo sendo a variável controladora e a organização dos dados em ordem cronológica sendo essencial. Alterar a sequência dos dados pode mudar significativamente as informações contidas na série (SILVA; SILVA, 1999). Essas observações podem ser coletadas em intervalos diários, mensais, trimestrais ou anuais, e exemplos incluem preços de ações, valores de exportação, PIB, vendas médias de um item, entre outros.

Souza, Samohyl e Miranda (2008), assim como Hyndmann e Athanasopolus (2013), apontam que as séries temporais exibem três padrões fundamentais: tendência, sazonalidade e ciclo. Uma tendência é identificada quando os dados exibem um crescimento ou declínio contínuo ao longo de um período, podendo até mudar de direção. Séries que se mantêm constantes ao longo do tempo não apresentam tendências identificáveis.

2.5 Redes Neurais Artificiais

Rauber (2005) destaca que um dos campos mais intrigantes da pesquisa atual é a simulação das habilidades cognitivas humanas. Atualmente, estão sendo criadas de máquinas projetadas para espelhar o comportamento inteligente típico dos humanos, refletindo nossas reações e processos de pensamento. A inteligência humana, notoriamente a mais avançada entre as formas de vida, tem como epicentro o cérebro, um órgão de complexidade extraordinária, impulsionado por neurônios interligados. Estas redes neurais são a base para a troca de informações que sustentam a inteligência biológica. O desafio contemporâneo é emular a estrutura e funcionalidade do cérebro humano no âmbito tecnológico. Este ramo de pesquisa busca desvendar como a inteligência é manifestada nos neurônios e desenvolver estruturas artificiais que integram hardware e software da mesma maneira. O objetivo é transpor redes neurais biológicas para o domínio das RNA.


Ganeva e Mohie (2019) elucidam que as Redes Neurais Artificiais (RNA) funcionam de maneira similar à configuração dos neurônios em nosso sistema

biológico. Constituídas por uma série de neurônios, que servem como pilares essenciais de processamento, essas redes são responsáveis por realizar cálculos matemáticos complexos para gerar resultados específicos a partir de dados de entrada. Com o progresso significativo no campo do aprendizado profundo em anos recentes, as Redes de Memória de Longo e Curto Prazo (LSTM, em inglês) e suas variações se tornaram as opções mais atraentes para pesquisadores que se debruçam sobre questões vinculadas à análise de séries temporais (ZHANG, 2020).

Conforme Rauber (2005), uma Rede Neural Artificial (RNA) é composta por duas partes fundamentais: sua arquitetura e o algoritmo de aprendizado. Esses componentes derivam do paradigma de treinamento da rede, uma característica inerente a esses sistemas. Enquanto um computador baseado na arquitetura de von Neumann é configurado por programação, uma RNA é capacitada através de exemplos. O conhecimento relevante sobre o problema em questão está encapsulado nos exemplos de treinamento, que devem estar disponíveis obrigatoriamente. O algoritmo de aprendizagem generaliza esses dados e incorpora o conhecimento nos parâmetros ajustáveis da rede, ou seja, nos pesos. Dessa forma, o criador de um sistema baseado em RNA tem duas variáveis essenciais: a escolha do tipo de rede para resolver o problema em questão e a seleção do algoritmo para treinar a rede, ou seja, para ajustar seus pesos.

De acordo com Aggarwal (2018) redes neurais podem conter uma ou múltiplas camadas. Na rede de camada única, um conjunto de entradas é diretamente mapeado para uma saída usando uma variação generalizada de uma função linear. Essa instância simples de uma rede neural é também conhecida como Perceptron, representado na Figura 2. Nas redes neurais de múltiplas camadas, os neurônios são organizados de forma estratificada, onde as camadas de entrada (Input Nodes) e saída (Output Node) são separadas por um grupo de camadas ocultas.


Figura 2 – Arquitetura básica de um Perceptron



Fonte: Aggarwal (2018)

Uma RNA pode ser formada por um ou por um grupo de Perceptrons, em uma camada única ou mesmo por várias camadas de Perceptrons, como exemplificado através da figura 3, a seguir. Todas as RNA possuem obrigatoriamente uma camada de entrada e uma camada de saída. Entretanto, quando possui duas ou mais camadas ocultas, ela é categorizada como uma Rede Neural Profunda (DNN) e seu processo de treinamento é reconhecido como Deep Learning (SIQUEIRA,2021).

Figura 3 – DNN com 2 camadas ocultas



Fonte: Aggarwal (2018)

2.6 Linguagem de Programação Python

Conforme Van Rossum e Drake Jr (1995), Python é destacado por sua simplicidade de uso, ao mesmo tempo em que oferece uma estrutura robusta para projetos de maior escala, superando a linguagem shell neste aspecto. Comparado ao C, Python se sobressai em verificar erros e incorpora tipos de dados avançados como arrays flexíveis e dicionários, que seriam complexos e demorados para criar em C. A linguagem se mostra versátil, abrangendo uma gama mais ampla de problemas do que linguagens como Awk ou Perl, mantendo a facilidade de uso para muitas tarefas.

Borges (2014) observa que a linguagem Python é notavelmente popular e influente entre as linguagens de programação dinâmicas. Sua popularidade é evidenciada pela existência de uma comunidade ativa e engajada de usuários globalmente, que contribuem para listas de discussão vibrantes e um amplo conjunto de ferramentas de código aberto.

Cardoso (2023) ressalta a utilização crescente da linguagem Python em simulações de modelos devido ao seu extenso repertório de bibliotecas. Complementando essa ideia, Padilha e Carvalho (2017) destacam a versatilidade dessas bibliotecas Python, especialmente no que se refere ao desenvolvimento de códigos para aplicações em diversas áreas, incluindo a mineração de dados, demonstrando a amplitude e a adaptabilidade da linguagem em diferentes campos do conhecimento.

3 METODOLOGIA DA PESQUISA

Neste estudo, a opção pelo método quantitativo se justifica pela sua reconhecida eficiência em proporcionar análises objetivas e minuciosas dos dados, possibilitando uma compreensão detalhada do fenômeno em questão. Como apontam Sampieri, Collado e Lucio (2013), uma das principais características da metodologia quantitativa é a habilidade de medir fenômenos e empregar métodos estatísticos. Esta abordagem, tipicamente, adota uma sequência processual metodológica, abordando a realidade de uma maneira objetiva.

Creswell (2014) salienta a utilidade da pesquisa quantitativa na verificação de teorias objetivas, explorando as relações entre variáveis. Tal abordagem geralmente envolve a coleta de dados por meio de instrumentos padronizados, que são então

submetidos a análises estatísticas. Esta metodologia está em perfeita consonância com o propósito deste trabalho, que visa realizar uma análise objetiva e rigorosa dos dados relacionados à previsão de demanda de combustível.

Conforme a classificação proposta por Vergara (2010), a pesquisa é categorizada considerando dois aspectos: seus fins e seus meios. Em relação aos fins, a pesquisa é categorizada como aplicada, dado que seu propósito é a utilização prática dos conhecimentos adquiridos com intuito de otimizar a previsão de demanda de combustível na Marinha do Brasil. Vergara (2010) postula que a pesquisa aplicada é crucial por voltar-se diretamente à resolução de problemas concretos, sejam eles imediatos ou de longo alcance. Em distinção à pesquisa básica, que é impulsionada pela mera curiosidade intelectual e se situa predominantemente no terreno da teoria, a pesquisa aplicada busca, de forma pragmática, soluções tangíveis para dilemas genuínos.

O estudo, ainda, se enquadra na categoria de pesquisa descritiva. Segundo Gil (2002), esse tipo de pesquisa objetiva descrever as características de uma determinada população ou fenômeno. Sob essa ótica, a investigação traça o comportamento histórico da demanda de combustível na Marinha, baseando-se em registros anteriores. Tal método procura oferecer uma visão clara e detalhada do estado atual, bem como das tendências observadas no passado, clarificando os atributos intrínsecos deste fenômeno em estudo.

Quanto aos meios, essa pesquisa é classificada como documental, ao realizar a análise dos relatórios de fornecimento extraídos do SINGRA. A pesquisa documental surge como uma metodologia que pode assumir uma perspectiva inovadora, proporcionando importantes insights para estudos em diversas áreas. Além disso, os documentos são amplamente aceitos como fontes de dados cruciais, ressaltando sua importância no contexto da análise e interpretação (GODOY, 1995)

Conforme mencionado na introdução do trabalho, foram realizadas primeiramente pesquisas por trabalhos acadêmicos que debatessem sobre a previsão de demanda na MB. Posteriormente, foram feitas diversas pesquisas que auxiliassem e embasassem esse estudo através de pesquisas utilizando o Google Acadêmico, a biblioteca EBSCO e a biblioteca virtual Naval Postgraduate School's Dudley Knox Library, utilizando palavras chaves como “Previsão de demanda”, “Series temporais” e “Redes Neurais Artificiais”, tanto em português como em inglês.

Os dados relativos ao histórico de fornecimento de combustíveis foram coletados junto à Gerência de CLG do Centro de Operações do Abastecimento (COpAb). Nesse processo, os dados referentes a um período de seis anos de fornecimento de combustíveis para toda a Mb foram coletados a partir da extração de relatórios disponíveis no Sistema de Informações Gerenciais do Abastecimento (SINGRA).

Durante todo o processo de coleta de dados, foi mantido um foco rigoroso na integridade e confiabilidade das fontes utilizadas. Ao evitar entrevistas estruturadas e confiar em dados documentais e já publicados, esta pesquisa garantirá uma abordagem objetiva e fundamentada para analisar se é possível realizar um modelo de previsão mais assertivo utilizando RNA.

Os dados analisados constituem um compêndio das Requisições de Material de Consumo (RMC), emitidas pelas Organizações Militares Consumidoras (OMC) no SINGRA, que foram fornecidas. Para este estudo, foram compiladas seis planilhas em Excel, uma para cada ano, abrangendo o período de 2016 a 2022, totalizando cerca de 40 mil linhas em cada planilha.

Após a obtenção desses registros históricos de fornecimento, eles foram importados e processados utilizando a biblioteca Pandas em Python. Esta etapa marcou o início da análise exploratória dos dados, que incluiu a verificação da integridade, identificação de possíveis duplicatas, correção de erros na leitura dos números nas tabelas como, por exemplo, a detecção de pontos utilizados para separar milhares, e a interpretação da distribuição desses dados ao longo do período em estudo.

Nesta etapa, analisou-se a classificação da demanda de cada item, por meio de um código em python que calcula o ADI e o CV com base nos dados de fornecimento e que ao final do teste armazena os resultados em uma planilha Excel. O objetivo é entender melhor o comportamento da demanda ao longo do tempo. Conseqüentemente, melhorando a modelagem de previsão para cada tipo de demanda.

Em seguida, os dados são importados em outro código. O script Python carrega os dados históricos para treinar e validar um modelo que utiliza a biblioteca NeuralProphet para previsão de séries temporais. A função 'objetivo' é utilizada para otimizar os parâmetros do modelo através de 200 tentativas, buscando minimizar o Erro Absoluto Médio Padronizado (MASE) e a Raiz do Erro Quadrático Médio Padronizado (RMSSE) das previsões, com os melhores parâmetros sendo exibidos ao final do processo de otimização.

Logo após os parâmetros do NeuralProphet serem otimizados, um terceiro código é utilizado, para realizar a previsão. Então, os dados são agrupados por data e somados para obter valores mensais. A série temporal resultante é utilizada para treinar um modelo NeuralProphet, que é ajustado com parâmetros específicos, já otimizados, para capturar tendências e sazonalidades nos dados. O modelo é treinado com um conjunto de treino e validado em um conjunto separado para avaliar sua capacidade de prever dados futuros.

Após ser devidamente treinado, o modelo é aplicado para gerar previsões. Essas previsões são, então, avaliadas em comparação com as metodologias de previsão empregadas pelo SINGRA. A eficácia do modelo é mensurada conforme definido por Hyndman e Koehler (2006), confrontando os valores previstos com os dados de teste reais, utilizando RMSSE e MASE como métricas específicas para determinar a precisão dos resultados obtidos.

4 ANÁLISE DOS RESULTADOS

Esta seção tem como foco a interpretação dos resultados obtidos pelo modelo de previsão em contraste com métodos de previsão do SINGRA. O modelo, embasado em Redes Neurais Artificiais, foi submetido a uma metodologia quantitativa, visando aferir sua precisão e utilidade prática. Os resultados aqui discutidos refletem a eficácia do modelo na previsão de demanda de combustíveis dentro da Marinha do Brasil e as implicações desses achados para a otimização da gestão logística. Para tal, primeiramente foi realizado um estudo dos dados para entender a classificação da demanda.

4.1 Classificação da Demanda

Este estudo iniciou com o desenvolvimento de um script básico em Python com a finalidade de analisar as planilhas de fornecimento de modo a classificar a demanda de cada tipo de combustível. O resultado desse script é apresentado na Tabela 1, a seguir.

Tabela 1 – Resultado Classificação da Demanda

Nome do Arquivo	ADI	CV	Classificação da Demanda	
GASOLINA COMUM	0	0,223290425	Regular	
ÓLEO DIESEL ESPECIAL MB	0,01408450	7	0,704033571	Errático
ÓLEO DIESEL MARITIMO	0	0,445367735	Regular	
ÓLEO DIESEL RODOVIÁRIO	0	0,293837	Regular	
QAV-1	0	0,667072985	Errático	
QAV-5	0,05882352	9	0,901187926	Errático

Fonte: Elaborado pelo autor (2023).

A análise dos padrões de demanda para diferentes produtos, utilizando o Intervalo Médio entre as Demandas (ADI) e o Coeficiente de Variação (CV), conforme os métodos de Syntetos et al. (2005), revela insights distintos para a gestão de estoque e planejamento do fornecimento dos combustíveis. A Gasolina Comum e o Óleo Diesel Marítimo, com ADI de 0 e CV abaixo de 0,49, exibem uma demanda regular e previsível, indicando uma variabilidade limitada e uma constância no fornecimento. Por outro lado, o Óleo Diesel Especial MB, com um CV de 0,704, e os produtos QAV-1 e QAV-5, com CV de 0,661 e 0,901, respectivamente, são caracterizados por uma demanda errática, marcada por uma variação substancial na quantidade demandada em relação à média, desafiando os modelos de previsão tradicionais e exigindo abordagens mais sofisticadas para acomodar tais flutuações.

Produtos com demanda regular, como a Gasolina Comum e o Óleo Diesel Marítimo, se alinham bem com métodos de previsão mais tradicionais e lineares, que pressupõem pouca variação e alta previsibilidade. Em contraste, produtos como o Óleo Diesel Especial MB e os combustíveis de aviação QAV-1 e QAV-5, que exibem uma demanda errática, necessitam de modelos de previsão mais complexos, como os métodos de séries temporais utilizando RNA.

4.2 Análise exploratória dos dados

Foram coletados os dados de 2017 a 2022 referentes ao fornecimento de combustíveis na MB. Estes dados foram adquiridos diretamente do COpAb, com o intuito de possibilitar uma análise prognóstica acurada da demanda de combustíveis para o ano subsequente.

A fim de preparar a base de dados para análises subsequentes, os dados foram inicialmente importados para um ambiente de programação Python. As etapas iniciais de tratamento dos dados incluíram a consolidação dos registros em uma frequência mensal, bem como a conversão dos dados temporais, originalmente em formato de texto, para o formato de data compatível com o Python, conhecido como objetos 'datetime'.

Prosseguindo com a análise, as Figuras 4 a 9 ilustram gráficos que desdobram a série temporal analisada em seus componentes constituintes, evidenciando a tendência, sazonalidade e os resíduos.

Figura 4: Decomposição da Série Temporal de Gasolina




Fonte: Elaborado pelo autor (2023)

Para o fornecimento de Gasolina, observou-se que a série original flutua entre 0 e aproximadamente 200.000, com variações significativas que indicam a presença de padrões complexos. A tendência, ao longo do período observado, demonstrou um declínio suave, começando por volta de 130.000, o que sugere uma redução gradual na métrica central ao longo do tempo.

Quanto à sazonalidade, notou-se um padrão regular e simétrico com oscilações consistentes em torno de uma linha de base nula, indicativo de influências sazonais previsíveis nos dados.

Finalmente, os resíduos apresentaram-se distribuídos em torno de zero, com variações contidas predominantemente entre -50.000 e +50.000, o que aponta para uma eficaz captura de variação pelos componentes de tendência e sazonalidade, deixando um componente residual que aparenta ser aleatório e sem estrutura definida.

Figura 5: Decomposição da Série Temporal de Óleo Diesel Especial MB (ODE)




Fonte: Elaborado pelo autor (2023)

A série temporal do ODE exibe valores com um pico inicial ultrapassando 2 milhões, seguido por variações que se estabilizam abaixo deste máximo. A linha de tendência declina abruptamente no início do período analisado, nivelando-se em torno de 1 milhão, o que denota uma mudança significativa na direção dos valores da série ao longo do tempo.

O componente sazonal ilustra flutuações robustas e periódicas, com picos e vales oscilando simetricamente em torno de uma linha central, refletindo uma sazonalidade expressiva com uma amplitude aproximada de 1 milhão.

Por fim, os resíduos apresentam-se distribuídos de forma bastante dispersa, com uma concentração de pontos em torno de zero, mas com alguns desvios que alcançam até 1 milhão, sugerindo a presença de elementos irregulares ou eventos atípicos na série que não são explicados pelos componentes de tendência e sazonalidade.

Figura 6: Decomposição da Série Temporal de Óleo Diesel Marítimo (ODM)



Fonte: Elaborado pelo autor (2023)


Já o fornecimento de ODM demonstra uma série de picos e vales com valores atingindo um máximo de aproximadamente 4 milhões, e uma variação que se mantém relativamente estável no tempo, embora com oscilações notáveis. A linha de tendência subsequente revela uma curva mais suave que inicialmente se apresenta em declínio, alcançando um valor próximo a 1,5 milhões, e posteriormente ascendendo, o que sugere uma inversão na direção da tendência no período mais recente.

O componente sazonal mostra um padrão cíclico claro com uma periodicidade constante e uma amplitude que se mantém em torno de 500.000 acima e abaixo da linha base, indicando um efeito sazonal significativo e consistente.

Por fim, os resíduos estão dispersos de maneira mais uniforme em torno da linha de base, com a maioria dos pontos concentrados entre -1 milhão e +1 milhão.

Essa distribuição de resíduos sugere que, embora a tendência e sazonalidade captem a maior parte da variação nos dados, ainda existem flutuações irregulares que podem ser atribuídas a fatores não capturados pelo modelo.

Figura 7: Decomposição da Série Temporal de Óleo Diesel Rodoviário (ODR)




Fonte: Elaborado pelo autor (2023)

A série temporal original mostra oscilações regulares com picos que sugerem eventos de alta magnitude, atingindo até 5 milhões. A tendência revela um aumento progressivo do consumo a partir de 2021 após um período de tendências descendentes desde 2017.

A sazonalidade exhibe variações periódicas e regulares, sugerindo padrões sazonais no consumo de diesel. Os resíduos, por sua vez, apresentam uma dispersão em torno do zero, com a maioria dos pontos flutuando entre -1 milhão e 1 milhão, o que indica que as variações significativas da série foram amplamente capturadas pelo modelo, deixando um componente residual de variações menores e aparentemente aleatórias.

Figura 8: Decomposição da Série Temporal de QAV-1




Fonte: Elaborado pelo autor (2023)

Para o QAV-1, a série temporal apresenta flutuações marcantes e picos esporádicos, possivelmente indicando eventos isolados ou efeitos sazonais pronunciados. A tendência mostra um crescimento lento e progressivo ao longo do tempo, sugerindo um acúmulo ou aumento gradual na série analisada. E a sazonalidade revela um padrão periódico e consistente, apontando para influências cíclicas no comportamento da série.

Quanto aos resíduos, por sua vez, encontram-se distribuídos ao redor da linha de base zero, majoritariamente dentro de um intervalo que sugere que a maior parte das variações foi capturada pelos componentes de tendência e sazonal. Isso indica que o modelo de decomposição foi bem-sucedido em explicar a série temporal, com as flutuações restantes representando o ruído ou as variações aleatórias não explicadas pelos outros componentes.

Figura 9: Decomposição da Série Temporal de QAV-5



Fonte: Elaborado pelo autor (2023)

A série temporal do consumo de QAV-5 mostra variações consistentes, com picos e vales ocorrendo em intervalos regulares, indicando padrões de comportamento sazonal ao longo do tempo, com valores oscilando em torno de 200.000. A linha de tendência, no segundo painel, exibe um aumento gradual e mais suave, começando em torno de 25.000 e alcançando cerca de 75.000, o que sugere um crescimento contínuo ao longo do período observado, sem flutuações drásticas.

No terceiro painel, o componente sazonal mostra uma oscilação clara e regular, com picos e vales correspondentes consistentemente ao longo do tempo, destacando uma forte componente sazonal na série.

Finalmente, os resíduos parecem ser relativamente pequenos e dispersos aleatoriamente ao redor da linha de base zero, o que indica que o modelo de decomposição conseguiu explicar a maioria das variações na série temporal, deixando um componente residual que representa o ruído ou as variações aleatórias que não são explicadas pelos componentes de tendência ou sazonalidade.

4.3 Métricas de avaliação

De acordo com Carvalho (2018), o SINGRA utiliza três técnicas para estimar demanda, todas baseadas em análise de séries temporais. Estas técnicas incluem a utilização da média móvel, amortecimento exponencial, bem como a aplicação da regressão linear para estimar a demanda.

Conforme definido por Hyndman e Koehler (2006), para avaliar o desempenho das previsões geradas, aplicamos métricas em cada previsão projetada para "i" passos à frente em comparação aos valores reais correspondentes, calculando a média do erro em todos os passos. Utilizamos duas métricas principais: o Erro Absoluto Médio Padronizado (MASE) e o Raiz do Erro Quadrático Médio Padronizado (RMSSE),

O RMSSE é calculado como a Raiz do Erro Quadrático Médio (RMSE) do método avaliado dividido pelo RMSE de uma previsão Naive. Este representa o análogo quadrático do MASE. Naive, neste contexto, refere-se à previsão em que o próximo valor é assumido ser idêntico ao último valor observado. As métricas MASE e RMSSE permitem avaliar o desempenho de um método em comparação direta com a previsão Naive, onde um valor inferior a um indica uma melhoria. Além disso, por serem quantidades escaladas, essas métricas possibilitam a comparação entre diferentes modelos em diferentes conjuntos de dados (TRIEBE, 2021).

4.4 Escolha da biblioteca NeuralProphet para realizar a previsão

Para satisfazer o segundo objetivo desta pesquisa, inicialmente, considerou-se a construção de uma rede neural artificial (RNA) personalizada para a realização de previsões. Contudo, devido à limitação temporal e à intrincada natureza do projeto, decidiu-se adotar o uso de uma biblioteca Python pré-existente especializada em tarefas preditivas. Em meio ao processo de revisão bibliográfica e avaliação de ferramentas potenciais, identificou-se a biblioteca NeuralProphet (NP) como sendo notavelmente superior às alternativas disponíveis.

Esta escolha foi fundamentada em sua capacidade de integrar robustez em previsões com uma abordagem prática e eficiente, o que se alinha com as necessidades metodológicas deste trabalho. A escolha foi também estratégica, permitindo direcionar o foco do estudo para a aplicação e interpretação dos resultados preditivos em vez de se embrenhar nas complexidades do desenvolvimento de algoritmos de RNA do zero.

De acordo com Triebe (2021), o NP é um modelo híbrido que integra os componentes clássicos de séries temporais do pacote Prophet com módulos de redes neurais (NN), permitindo a adaptação a dinâmicas não-lineares. Ele incorpora componentes de redes neurais como a autorregressão e módulos de covariáveis, utilizando o PyTorch como plataforma, o que o mantém atualizado com as mais recentes inovações em Deep Learning.

O pacote é acessível para quem não é especialista em previsão, oferecendo configurações padrão robustas e automatizando várias decisões de modelagem. Usuários avançados também podem personalizar o pacote, incorporando conhecimento especializado através de diversas opções de customização. Em resumo, o NP simplifica o conhecimento especializado em previsão e integra as melhores práticas de Machine Learning (ML), permitindo que os usuários se concentrem especificamente na tarefa que têm em mãos.

4.5 Modelo Computacional para previsão

Nesta fase do trabalho, será detalhada a implementação dos códigos desenvolvidos para o modelo de previsão. O primeiro código consiste em uma ferramenta de otimização de parâmetros, desenhada para refinar a configuração do modelo NeuralProphet. Tal ajuste influencia diretamente a capacidade do modelo de

discernir e seguir tendências e padrões inerentes aos dados históricos de fornecimento de combustíveis.

O segundo código é dedicado à execução efetiva das previsões, empregando os parâmetros otimizados identificados pelo primeiro código. Após a geração das previsões, o código procede à avaliação quantitativa do modelo, aplicando as métricas de desempenho estabelecidas previamente. A precisão e robustez dessas métricas são imprescindíveis para validar a confiabilidade e a aplicabilidade do modelo na previsão do fornecimento de combustível em cenários reais.

Inicialmente, o primeiro código configura um estado de aleatoriedade constante e define o nível de log, garantindo que os resultados sejam reproduzíveis e que apenas mensagens de aviso sejam impressas. Os dados são carregados a partir de um arquivo Excel com duas colunas, uma de datas e outra com valores agregados mensalmente. Os dados então são separados em dados de treinamento e validação. Para esse modelo, os dados de validação referentes a 2022. Os outros são utilizados para o treinamento do modelo.

O código define duas funções de avaliação de erro a RMSSE e a MASE, que são usadas para avaliar a acurácia das previsões do script em comparação com os valores reais de 2022.

A função objetivo é o coração da otimização, onde são definidos os parâmetros a serem otimizados pelo Optuna. Estes incluem configurações como o tipo de crescimento do modelo, a quantidade e o intervalo dos pontos de mudança, que indicam mudanças significativas na tendência dos dados, e os reguladores de tendência e sazonalidade, que ajudam a evitar o sobre ajuste do modelo. O modelo NeuralProphet é treinado com estes parâmetros e as previsões são geradas.

O Optuna é utilizado para executar a otimização, buscando minimizar a métrica combinada (a soma de MASE e RMSSE) ao longo de várias tentativas. Após a conclusão, o conjunto de parâmetros que resulta no menor erro é considerado o "melhor" e é salvo em um arquivo Excel, juntamente com um identificador único gerado (UUID) para fins de rastreamento.

Em resumo, o código automatiza o processo de ajuste fino de um modelo NeuralProphet para dados de séries temporais, empregando otimização bayesiana para selecionar os parâmetros que produzem as previsões mais precisas. Isso demonstra uma abordagem sofisticada e eficiente para modelagem de séries temporais, aproveitando tanto técnicas de aprendizado de máquina avançadas quanto métodos de otimização de parâmetros.

Nesse contexto, prosseguimos com o segundo código, que estabelece uma semente aleatória para garantir a reprodutibilidade dos resultados. Em seguida, carrega os dados de um arquivo Excel, focando em duas colunas: 'ds' para a data e 'y' para a variável de interesse (quantidade fornecida). Os dados são agregados e configurados para uma frequência mensal, e uma decomposição sazonal é aplicada e visualizada para entender as tendências e padrões sazonais subjacentes (Figuras 4 a 9).

O modelo principal utilizado é o NeuralProphet, uma variante do Prophet desenvolvido pelo Facebook, mas com uma abordagem baseada em redes neurais para a modelagem de séries temporais. O modelo é configurado com os parâmetros otimizados pelo primeiro código, incluindo o tipo de crescimento, número e alcance dos pontos de mudança, e regularizações da tendência e sazonalidade.

Além disso, uma série de modelos de baseline (Regressão linear, Média Móvel e Amortização Exponencial) são criados para comparação, incluindo regressão linear

simples, previsão pela média, média móvel e média móvel exponencial. Estes servem para fornecer uma referência de desempenho para o NeuralProphet.

O conjunto de dados é dividido em dados de treino e validação. O modelo NeuralProphet e os modelos de baseline são então ajustados aos dados de treino e usados para fazer previsões nos dados de validação.

Para avaliar o desempenho dos modelos, o código define duas métricas: RMSSE e MASE, como já abordado anteriormente. Ambas são métricas robustas para comparar a precisão das previsões, levando em conta a escala dos dados de treino e as diferenças em relação aos valores reais.

As previsões de todos os modelos são visualizadas em um gráfico juntamente com os dados reais para uma comparação visual. Por fim, os resultados das métricas para cada modelo são compilados em um dicionário e convertidos em um DataFrame do pandas, que é então exportado para um arquivo Excel. Este processo não apenas fornece uma avaliação quantitativa, mas também um meio conveniente de reportar e comparar o desempenho dos diferentes modelos de previsão. Tais desempenhos serão analisados na próxima seção desse trabalho.

4.6 Análise dos resultados encontrados

Subsequentemente à otimização dos parâmetros do modelo, procedeu-se à previsão temporal de 12 meses, seguida pela execução dos testes de validação pertinentes. Os resultados obtidos foram consolidados e são apresentados na Tabela 2, destacando em verde os melhores resultados, por tipo de combustível.

Tabela 2: Resultado da validação do modelo de previsão

Model	Gasolina		ODE	
	RMSSE	MASE	RMSSE	MASE
NeuralProphet	0,544705354	0,592038496	0,63684373	0,561168845
Regressão Linear	0,627280651	0,69412536	0,659363722	0,728867129
Média Móvel	0,756221127	0,848521631	0,74181776	0,768714701
Amortização Exponencial	0,728973372	0,786408638	0,66674882	0,699953212
Modelo	ODM		ODR	
	RMSSE	MASE	RMSSE	MASE
NeuralProphet	0,98050747	0,923124317	0,613869	0,678778
Regressão Linear	1,28716318	1,223459111	1,44203	1,674793
Média Móvel	1,303605389	1,289206101	1,285927	1,378705
Amortização Exponencial	1,282047929	1,236408426	1,274548	1,383513
Modelo	QAV-5		QAV-1	
	RMSSE	MASE	RMSSE	MASE
NeuralProphet	0,987182111	1,101933233	0,243141933	0,442111883
Regressão Linear	1,113044542	1,097643997	0,291236145	0,481631802
Média Móvel	1,154086043	1,152367456	0,433124713	0,721748482
Amortização Exponencial	1,104658558	1,078239377	0,377707457	0,654584006

Fonte: Elaborado pelo autor (2023)

Para a Gasolina, o modelo apresenta um RMSSE de 0,544705354, o que representa uma precisão substancialmente maior nas previsões quando comparado com as outras abordagens. Isso implica que as previsões geradas por este modelo

estão mais próximas dos valores reais observados. O MASE de 0,592038496 para Gasolina também é o mais baixo entre os modelos testados, indicando que, em média, o modelo tem o menor erro absoluto em relação à escala dos dados.

Analisando os resultados para ODM e ODR, o melhor valor é mantido com RMSSE de 0,98050747 e 0,613869, respectivamente. Estes números sugerem que o modelo é robusto mesmo quando aplicado a diferentes tipos de combustíveis com padrões de demanda distintos. A consistência do algoritmo em obter os menores valores de MASE para ODM (0,923124317) e ODR (0,678778) reforça sua aplicabilidade como uma ferramenta de previsão confiável.

O desempenho do modelo nos querosenes de aviação, QAV-5 e QAV-1, também é notável. O modelo registra um RMSSE de 0,987182111 para QAV-5, superando outros modelos e evidenciando sua capacidade de prever com precisão mesmo em séries temporais complexas e voláteis. O MASE para QAV-5 é ligeiramente superior ao de outros métodos, mas ainda assim apresenta um valor competitivo de 1,101933233, sustentando a qualidade das previsões. No caso do QAV-1, os resultados são igualmente impressionantes, com o modelo NeuralProphet alcançando o menor RMSSE (0,243141933) e o menor MASE (0,442111883), confirmando a eficiência do modelo em capturar as tendências e padrões nos dados de consumo de combustível.

5 CONSIDERAÇÕES FINAIS

Este estudo buscou responder se a aplicação de Redes Neurais Artificiais (RNA) poderia otimizar a previsão de demanda de Combustíveis, Lubrificantes e Graxa (CLG) na Marinha do Brasil (MB). Partindo de uma lacuna identificada na literatura sobre previsão de demanda de CLG utilizando RNA no contexto específico da MB, o trabalho desenvolveu e analisou um sistema computacional destinado a esse fim.

A análise da classificação da demanda de CLG, aliada à realização de uma análise exploratória dos dados, proporcionou uma base sólida para o desenvolvimento do modelo de RNA proposto. Os testes subsequentes e o treinamento do modelo visaram não apenas aferir a precisão das previsões, mas também a adequação prática do modelo em um contexto operacional realista.

A análise comparativa do desempenho de vários modelos de previsão na tarefa de estimar a demanda de combustíveis para a Marinha do Brasil revela uma superioridade significativa do modelo NeuralProphet sobre os métodos convencionais. Com a menor pontuação em RMSSE em todos os tipos de combustível testados, demonstra sua eficácia na captura da variabilidade dos dados e na minimização dos erros de previsão.

A eficácia do modelo proposto é corroborada pela sua capacidade adaptativa, evidenciada pela otimização de parâmetros. Essa adaptabilidade é reforçada pelo desempenho superior do modelo em comparação com abordagens tradicionais de previsão no contexto de demandas classificadas como regulares.

A superação dos modelos convencionais de previsão sublinha a robustez e a flexibilidade do modelo de Redes Neurais Artificiais (RNA) otimizado. Tal robustez é demonstrada pela precisão das previsões geradas, que se mantêm consistentes independentemente da variabilidade intrínseca das séries temporais analisadas.

Os resultados obtidos assumem uma relevância notável no contexto operacional da Marinha do Brasil, considerando que previsões precisas de demanda são fundamentais para um planejamento logístico eficiente e uma gestão de recursos

otimizada. Assim, a implementação do modelo baseado em Redes Neurais representa um salto qualitativo, com o potencial de gerar economias significativas em termos de tempo, custos e eficácia operacional.

Em suma, o modelo computacional desenvolvido com o auxílio da biblioteca NeuralProphet demonstrou ser uma ferramenta robusta e confiável na previsão da demanda de combustíveis. Este modelo se destaca diante dos métodos tradicionais, emergindo como uma opção promissora para aprimorar a capacidade preditiva na Marinha do Brasil. Para trabalhos futuros, é recomendável explorar mais amplamente o uso de métodos avançados de aprendizado de máquina e aprendizado profundo em contextos similares de previsão de séries temporais, incorporando variáveis adicionais ao modelo para enriquecer sua precisão e abrangência.

NOTAS

Link para acesso aos dados utilizados na pesquisa e scripts implementados:
<https://drive.google.com/drive/folders/1DtWGuYUasCXUUTGYI-f83qUcGV-4HMbp>

REFERÊNCIAS

AGGARWAL, Charu C. et al. **Neural networks and deep learning**. Springer, v. 10, n. 978, 2018.

ARMSTRONG, Jon Scott (Ed.). **Principles of forecasting: a handbook for researchers and practitioners**. Boston, MA: Kluwer Academic, 2001.

BALLOU, Ronald H. **Gerenciamento da Cadeia de Suprimentos-: Logística Empresarial**. Bookman editora, 2009.

BENTES, K. da Paz. **Fundamento do Centro de Controle de Inventário da Marinha**. 2019. Tese de Doutorado. PUC-Rio.

BORGES, Luiz Eduardo. **Python para desenvolvedores: aborda Python 3.3**. Novatec Editora, 2014.

BLUVOL, Leonardo. **Análise de algoritmos de machine learning para previsão de preços de IBOVESPA**. 2022.

BRASIL. Marinha do Brasil. Secretaria Geral da Marinha. **SGM-201: Normas para Execução do Abastecimento**. 7ª. rev. 2020

CARDOSO, Heitor Thurler. **Aplicação do SCADABR para monitoramento de sistemas de controle feedback simulado em ambiente Python**. 2023.

CARVALHO, Leonardo Rodrigues. **Previsão de demanda de material de saúde na Marinha do Brasil**. Rio de Janeiro, 2018.

CRESWELL, John W. **Projeto de pesquisa: métodos qualitativo, quantitativo e misto**. 2. ed. Tradução de Luciana de Oliveira da Rocha. Porto Alegre: Artmed, 2007.

DA SILVA, Fernando Rodrigues. **Previsão de demanda e planejamento comercial**. Editora Senac São Paulo, 2020.

DAVIS, Mark M.; CHASE, Richard B.; AQUILANO, Nicholas J. **Fundamentos da administração da produção**. Bookman, 2001.

DE CASTRO, Maria Cristina Felippetto. **Predição não-linear de series temporais usando redes neurais RBF por decomposição em componentes principais**. 2001. Tese de Doutorado. University of Campinas, Brazil.

DE MELLO, Luiz Sérgio Carvalho; CARDOSO, Leonardo Fogaça; PESSANHA, José Francisco Moreira. **Previsão de Demanda de Alimentos: estudo de caso na Marinha do Brasil**. 2021.

DIAS, G. P. P. **Proposta de processo de previsão de vendas para bens de consumo**. XIX Encontro Nacional de Engenharia de Produção, Rio de Janeiro: ABEPRO, 1999.

DOS SANTOS, Marcos et al. **Cálculo da previsão de demanda de uma multinacional**. Brazilian Journal of Development, v. 4, n. 6, p. 3035-3052, 2018.

DOS SANTOS, Marcos. **Proposta de um modelo de previsão de demanda de peças sobressalentes para navios de guerra da Marinha do Brasil**. 2016.

DOWNING, D; CLARK, J. **Estatística Aplicada**. 2 ed. São Paulo: Saraiva, 2006.

FERREIRA, Claudio José de Melo. **Gerenciamento de estoque de peças de uniformes na Marinha do Brasil**. 2012. Tese de Doutorado. PUC-Rio.

FERREIRA, Ricardo Vieira. **Previsão de demanda: um estudo de caso para o sistema interligado nacional**, 2006.

GAIT, Nazira. **Ajustamento sazonal de séries temporais**. 1975. Tese de Doutorado. Universidade de São Paulo.

GANEVA, Ivana; MOHIE, Rana. **Forecasting current crises: comparison of conventional methods and an artificial neural network model**. 2019.

GARCIA, R. A. **Análise dos Métodos de Previsão de Demanda: estudo de caso em unidades distintas de uma escola de idiomas**. São Mateus: UFES, 2011.

GERBER, J. Z.; MIRANDA, R. G. de; BORNIA, A. C.; FREIRES, F. G. M. **Organização de Referenciais Teóricos sobre Diagnóstico para a Previsão de Demanda**. Revista Eletrônica de Gestão Organizacional, Recife, v. 11. 2013.

GIL, Antonio Carlos et al. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2002.

HANKE, John E.; WICHERN, Dean W.; REITSCH, Arthur G. **Business forecasting**. 7ª ed. New York: Prentice Hall. 2001.

HIGUCHI, AGNALDO KEITI. **A previsão de demanda de produtos alimentícios perecíveis: três estudos de caso**. REA-Revista Eletrônica de Administração, v. 5, n. 2, 2006.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. OTexts, 2018.

HYNDMAN, Rob J.; KOEHLER, Anne B. **Another look at measures of forecast accuracy**. International journal of forecasting, v. 22, n. 4, p. 679-688, 2006.

LUNARDI, Roben Castagna. **Um analisador de intrusões baseado em Séries Temporais**. 2008.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting methods and applications**. 3ª ed. New York; John Wiley & Sons. 1998.

MAKRIDAKIS, S.G.; HIBON, M. **The M3-competition: Results, conclusions and implications**. International Journal of Forecasting (special issue), v.16. 2000.

MATTOS, Andrea Cilene de. **Diretrizes para o dimensionamento do número de unidades habitacionais de hotéis resort**. 2004. Tese de Doutorado. Universidade de São Paulo.

MOREIRA, D. A. **Administração da Produção e Operações**. 2.ed.São Paulo: Cengage, Learning, 2008.

PADILHA, Victor Alexandre; CARVALHO, ACPLF. **Mineração de dados em python. Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo**, 2017.

PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implementação de Sistemas de Previsão de Demanda - Técnicas e Estudo de Caso**. Revista Produção, v. 11. 2001.

PETRÔNIO, G. M; LAUGENI, P. F. **Administração da Produção**. 2ª ed. São Paulo. Ed.Saraiva. 2005.

RAUBER, Thomas Walter. **Redes neurais artificiais**. Universidade Federal do Espírito Santo, v. 29, 2005.

RITZMAN, Larry P.; KRAJEWSKI, Lee J. **Administração da produção e operações**. Prentice Hall, 2003.

ROSSELLÓ, Jaume; AGUILÓ, Eugeni; RIERA, Antoni. **Modeling tourism demand dynamics**. Journal of Travel Research, v. 44, n. 1, 2005.

SAMPIERI, R.; COLLADO, C.; LUCIO, M. **Metodologia de Pesquisa**. Porto Alegre, Rio Grande do Sul, Brasil: Penso Editora. 2013.

SILVA, E. M.; SILVA, E. M. **Matemática e Estatística Aplicada**. São Paulo: Atlas, 1999.

SIQUEIRA, Lucas Pavanelo. **Identificação e classificação de lixo doméstico através de rede neural convolucional: revisão e pesquisa de mercado**. 2021.

SOUZA, G. P.; SAMOBYL, R. W.; MIRANDA, R. G. **Métodos Simplificados de Previsão Empresarial**. Rio de Janeiro: Ciência Moderna, 2008.

SYNTETOS, Argyrios. **Forecasting of intermittent demand**. 2001. Tese de Doutorado. Brunel University.

SYNTETOS, Aris A.; BOYLAN, John E.; CROSTON, J. D. **On the categorization of demand patterns**. Journal of the operational research society, v. 56, 2005.

TRIEBE, Oskar et al. **Neuralprophet: Explainable forecasting at scale**. arXiv preprint arXiv:2111.15397, 2021.

VAN ROSSUM, Guido; DRAKE JR, Fred L. **Python tutorial**. Amsterdam, The Netherlands: Centrum voor Wiskunde en Informatica, 1995.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 12.ed. São Paulo: Atlas. 2010.

WERNER, L.; LEMOS, F. de O.; DAUDT, T.; **Previsão de Demanda e Níveis de Estoque uma Abordagem Conjunta Aplicada no Setor Siderúrgico**. XIII SIMPEP, Bauru, nov. 2006.

ZHANG, Fan. **Applications of artificial neural networks for time series data analysis in energy domain**. 2020. Tese de Doutorado. Dalarna University.