



De 11 a 14 - NOVEMBRO DE 2024

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



PROPOSTA DE UMA FERRAMENTA PARA ESTUDOS E DESENVOLVIMENTOS DE MÉTODOS DE PREVISÃO DE DEMANDA NA INDÚSTRIA

Saymon Galvão Bandeira - saymongb@gmail.com

Universidade Federal de Goiás - UFG

Dr^a. Symone Gomes Soares Alcalá - symone@ufg.br Universidade Federal de Goiás -
UFG

Dr. Roberto da Piedade Francisco - roberto.piedade@ufg.br Universidade Federal de
Goiás - UFG

ÁREA: 3. PESQUISA OPERACIONAL

SUBÁREA: 3.6 - ANÁLISE DE DEMANDA

RESUMO: PROBLEMAS DE PREVISÃO DE SÉRIES TEMPORAIS EMERGEM NA INDÚSTRIA SOB DIFERENTE CONTEXTOS. EM PARTICULAR, NOS SEGMENTOS RELACIONADOS A PEÇAS DE REPOSIÇÃO O DESAFIO DE ESTIMAR A DEMANDA CORRETA PARA DETERMINADOS ITENS PODE SER AINDA MAIOR. ISTO PORQUE TAIS ITENS PODEM APRESENTAR PADRÕES DE INTERMITÊNCIA, CHEGANDO A REPRESENTAR BOA PARTE DO ESTOQUE. NESTE ESTUDO, É REALIZADA A PROPOSTA DE UMA FERRAMENTA PARA A PREVISÃO DE DEMANDAS NA INDÚSTRIA. A FERRAMENTA INCLUIRÁ MODELOS DE PREVISÃO, CLÁSSICOS E BASEADOS EM INTELIGÊNCIA ARTIFICIAL, PARA ITENS COM E SEM INTERMITÊNCIA. ALÉM DISSO, UMA INTERFACE COM USUÁRIO DE FÁCIL UTILIZAÇÃO SERÁ CRIADA COM OBJETIVO DE FACILITAR A APLICAÇÃO DOS MÉTODOS DE ÚLTIMA GERAÇÃO EM DADOS DE PROBLEMAS DO MUNDO REAL. UM LEVANTAMENTO DAS SOLUÇÕES ATUAIS EXISTENTES FOI REALIZADO E SERVIU COMO BASE PARA FUNDAMENTAR A PROPOSTA. TRATA-SE DE UMA FERRAMENTA PARA A EXECUÇÃO DE ESTUDOS DE PREVISÃO DE DEMANDAS E EXPERIMENTAÇÃO DE MODELOS PREDITIVOS. DESSE MODO, ESPERA-SE CONSTRUIR UMA PLATAFORMA QUE PERMITA GERAR PREVISÕES ACURADAS, A APLICAÇÃO DE TÉCNICAS AVANÇADAS DA LITERATURA EM PROBLEMAS REAIS E AINDA SERVIR COMO BASE PARA A EXPLORAÇÃO DE NOVOS MODELOS PREDITIVOS UTILIZANDO DADOS REAIS, TANTO NA INDÚSTRIA, QUANTO NA ACADEMIA.

PALAVRAS-CHAVES: PREVISÃO DE DEMANDA; SÉRIE TEMPORAL; INDÚSTRIA; FERRAMENTA.

1. INTRODUÇÃO

O planejamento realizado em diversas organizações é pautado, em algum grau, em informações que dizem respeito ao futuro. Por exemplo, na indústria, a demanda esperada pode direcionar a tomada de decisão sobre o planejamento do negócio, isto é, matéria prima, alocação de recursos e muitos outros (BATALHA, 2008, p. 42). Esta expectativa sobre a demanda pode ser visualizada como um problema de previsão de demanda.

Previsão de demanda consiste em predizer ou estimar a necessidade futura por um produto (ou serviço) (ARMSTRONG, 2001). Problemas de previsão de demanda são relevantes em diversos segmentos do mercado. Isto porque previsões inadequadas podem comprometer a performance financeira em função de altos custos associados a estoques excessivos, riscos de escassez, pedidos retroativos ou até mesmo redução no nível dos serviços oferecidos ao cliente final (FAGHIDIAN, 2021).

Em particular, a previsão de demanda em segmentos industriais relacionados ao consumo de peças de reposição tem desafios adicionais devido às características específicas deste tipo de demanda tais como intermitência e baixa movimentação de estoques. Na literatura, estudos reportam a representatividade de até 60% do volume do estoque para este tipo de item (YANG, 2021). No Brasil, apenas a indústria automotiva representa 4% do PIB e 20% do PIB da indústria de transformação, com cerca de 27 fabricantes e 446 empresas de autopeças, atendendo o quarto maior mercado do mundo (DAUDT & WILLCOX, 2018). Adicionalmente, no setor militar, a previsão apropriada para peças de reposição em tempos de guerra pode viabilizar os reparos em aeronaves em tempo hábil, tornando-se uma atividade essencial para a segurança nacional (LI *et al.*, 2020).

Para suprir tal necessidade, muitas organizações e universidades tem unido esforços para melhorar a qualidade preditiva dos modelos atuais. Por exemplo, o *International Institute of Forecasters* tem promovido competições de previsão (*M Competitions*) em que diversos profissionais e acadêmicos utilizam dados de problemas reais para desenvolver novos modelos de previsão, impulsionando assim o avanço do estado da arte nesse campo. A última edição da competição, o M5 (MAKRIDAKIS *et al.*, 2022), contou com dados de vendas de diversos produtos do *WallMart*. Segundo Makridakis (2022), a base fornecida pela empresa apresenta intermitência em aproximadamente 73% das séries temporais, destacando a importância do tema para outros segmentos para além da indústria de peças de reposição.

Para atender tal necessidade das organizações, muitas empresas se lançaram no mercado oferecendo soluções de prateleira e/ou até mesmo com possibilidade de customização. Como

resultado desta pesquisa, muitas soluções foram identificadas, no entanto nem todas consideram explicitamente segmentos relacionados as peças de reposição e podem gerar custos adicionais para as organizações interessadas. Portanto, o objetivo deste trabalho é propor e detalhar uma ferramenta para problemas de previsão de demanda na indústria. A arquitetura da ferramenta foi elaborada com base em um levantamento das soluções existentes no mercado e das suas principais características e lacunas existentes. Como característica, possuirá a possibilidade de aplicação direta de técnicas avançadas da literatura em problemas do mundo real. Desse modo, espera-se potencializar os processos de tomada de decisão pautados na demanda prevista no âmbito industrial. Além disto, a ferramenta contribuirá para o desenvolvimento e experimentação de modelos preditivos sendo sua aplicação validada em casos de uso de organizações do mundo real, tanto na indústria, quanto na academia.

O restante do trabalho está organizado conforme segue: na Seção 2, uma base teórica em previsão de demandas é introduzida; na Seção 3, resultados de um levantamento de soluções disponíveis no mercado são apresentados; na Seção 4, é realizada uma proposta de solução alternativa com ênfase em segmentos industriais; e na Seção 5, uma discussão sobre a proposta e próximos passos é realizada.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Análise da demanda

Problemas de previsão de demandas podem ser visualizados como um caso particular da previsão de séries temporais. Isto porque a maioria dos modelos atuais não levam em consideração algumas características específicas de uma série temporal de demandas (HYNDMAN & ATHANASOPOULOS, 2021). Tais características podem ser o fato de que a demanda não pode assumir valores negativos, o tamanho do intervalo entre a ocorrência de demandas consecutivas, a possibilidade de que os valores da demanda serem apenas números inteiros em alguns casos, entre outros.


No estudo de séries temporais, a existência ou não de determinada característica pode ser relevante, principalmente quando o desafio em questão é escolher um modelo em específico para gerar as previsões (FILDES & PETROPOULOS, 2015). Algumas séries podem apresentar sazonalidade, enquanto outras podem apresentar tendência no comportamento dos valores. Além disto, algumas séries podem ser estacionárias, o que significa que seu comportamento não muda no tempo.

Nos produtos da indústria, em especial, de peças de reposição, é comum na literatura

ser reportado séries de demandas intermitentes (YANG *et al.*, 2021). Séries de demandas intermitentes são séries em que a demanda ocorre em intervalos espaçados no tempo, podendo ainda apresentar alta variabilidade nos valores das demandas. Algum esforço na literatura tem sido realizado com o objetivo de categorizar as demandas (COSTANTINO *et al.*, 2018). Adicionalmente, pode-se realizar análises estatísticas com o objetivo de identificar a existência ou não de determinado padrão nas séries temporais, tais como testes para estacionariedade, estruturas de correlação e o exame do intervalo entre demandas (COSTANTINO *et al.*, 2018).

O intervalo entre demandas tem sido utilizado para classificar demandas como intermitentes ou não. Além disto, é possível combinar com alguma medida de variação do valor da demanda. Muitos autores utilizam como referência o *framework* de classificação de demandas intermitentes descrito por CHIEN *et al.* (2023). A ideia geral da proposta é apresentada na Figura 1 abaixo.

Figura 1: Pontos de corte para categorização de demandas.



Adaptado de (CONSTANTINO *et al.*, 2018)

Na Figura 1, o quadrado do Coeficiente de Variação (CV^2) é uma medida de variabilidade do valor da demanda enquanto o Intervalo Médio inter-demandas ou *Average Inter-demand Interval* (ADI) é uma medida de intermitência. Desse modo, quatro categorias podem ser estabelecidas, a saber:

- Suave (*Smooth*): valor da demanda e intervalo entre as ocorrências mais “comportado”,
- Errática (*Erratic*): alta variabilidade no valor da demanda, porém ainda não-intermitente,
- Intermitente (*Intermittent*): alto intervalo entre as ocorrências das demandas, e
- Granuloso (*Lumpy*): intermitente e com alta variabilidade nos valores das demandas.

Cumpramos ressaltar que, para além destas categorias, o padrão no comportamento do valor

da demanda pode ainda apresentar um comportamento com tendência de obsolescência, podendo ser repentina ou gradual.

2.2 Métodos para previsão

Na literatura, uma quantidade razoável de métodos tem sido proposta e submetida a criteriosos esquemas de validação. Destaca-se a aplicação da Suavização Exponencial (SE), uma abordagem que permite parametrizar a importância das observações mais antigas da série, controlada pelo parâmetro (α). A formulação do modelo é apresentada na Equação 1, abaixo:

$$\hat{y}_{t+1} = y_t + (1 - \alpha)\hat{y}_{t-1}, \quad (1)$$

onde, α é o parâmetro que controla a influência das observações mais antigas, y_t é o valor da demanda observada no instante t e $\hat{y}_{t+1}$ é uma previsão gerada pelo modelo (CROSTON, 1972).

Outra abordagem popular, específica para demandas intermitentes, foi proposta por Croston (1972). O método de Croston (CR) trata-se da aplicação do SE a duas séries diferentes: uma série com os valores das demandas e a segunda com os intervalos entre demandas consecutivas. A premissa do método de Croston é que os intervalos das ocorrências e o valor das demandas são variáveis independentes (podendo então serem estimadas separadamente). Dessa forma, o modelo proposto é apresentado nas Equações 2, 3 e 4 a seguir:

$$z_t = \alpha y_t + (1 - \alpha)z_{t-1}, \quad (2)$$

$$\hat{p}_t = \alpha p_t + (1 - \alpha)\hat{p}_{t-1}, \quad (3)$$

$$\hat{y}_{t+1} = \frac{z_t}{\hat{p}_t} \quad (4),$$

onde p_t é o intervalo entre as duas últimas demandas observadas no instante t , $\hat{p}_t$ é o intervalo esperado no instante t , z_t é o valor esperado para a demanda e $\hat{y}_{t+1}$ é a previsão final. O trabalho de Croston foi pioneiro para o desenvolvimento de métodos para demandas intermitentes, influenciando toda uma geração de trabalhos posteriores a introdução do método CR.

Exemplos desses trabalhos são as propostas comparadas por Babai *et al.* (2019) considerando o método Syntetos-Boylan *Approximation* (SBA, que tratou da correção de um viés positivo identificado no método CR) e o método Teunter, Syntetos e Babai (TSB) que foi projetado para lidar com demandas intermitentes com risco de obsolescência. Existem ainda aplicações utilizando métodos bem conhecidos em disciplinas como Econometria, como o caso do Modelos Autoregressivos Integrados com Média Móvel (*Autoregressive Integrated Moving Average/ARIMA*), a média móvel (*Moving Average/AR*) e ainda estratégias mais simples como o método ingênuo (*Naive Forecast/NF*) (HYNDMAN & ATHANASOPOULOS, 2021).

Ainda no campo da Inteligência Artificial (IA), diversas técnicas foram adaptadas para

lidar com problemas de previsão de demandas, inclusive demandas intermitentes. Por exemplo, Zhang *et al.* (2023) propôs a aplicação de uma abordagem baseada em Rede Neural Artificial (RNA). Utilizando dados da indústria de peças de aeronaves, conseguiram mostrar uma boa performance preditiva, inclusive em relação as abordagens clássicas como SE e CR. Adicionalmente, pode-se encontrar aplicações utilizando modelos baseados em Floresta Aleatória (*Random Forest*/RF) e ainda Regressão Logística (RL) (KIM *et al.*, 2023).

Cada abordagem mencionada anteriormente possui características próprias, vantagens e desvantagens. Por exemplo, alguns métodos podem ser ajustados rapidamente como o caso do SE, ARIMA, CR (e suas variantes); no entanto, eles consideram explicitamente que determinadas características (intermitência, estacionariedade etc.) estão presentes nas séries temporais em que são aplicados (e isto pode não acontecer ou o padrão mudar com o tempo na prática). Por outro lado, as técnicas emergentes do estudo em IA não fazem suposição sobre o processo subjacente de geração dos dados, mas possuem a desvantagem de exigir equipamentos de hardware de alto desempenho para o treinamento dos modelos.

3. METODOLOGIA DA PESQUISA

Conforme introduzido na seção anterior, na literatura, uma série de métodos para previsão vem sendo desenvolvida. Desse modo, tomadores de decisão, ao se depararem com problemas de previsão de demanda, podem estar interessados em soluções disponíveis que consideram modelos para previsão na indústria, em particular, especializados para demanda intermitente. Diante disto, procedeu-se levantamento das soluções existentes de previsão de demanda com o objetivo de mapear as principais características e eventuais lacunas e pautar os principais requisitos da aplicação.

3.1 Levantamento soluções

O levantamento das soluções existentes foi realizado considerando as seguintes etapas: definição de campos para extração de informações, pesquisa em páginas Web, consolidação dos resultados e análise dos resultados. Os campos definidos para extração foram: nome da organização/solução, casos de uso apresentados, idioma, existência de custos, principais características (requisitos de *software*, *hardware*, recursos humanos) entre outros.

Durante a pesquisa, buscou-se verificar nos materiais disponíveis *on-line* as informações mencionadas anteriormente. Para isto um exame detalhado nas páginas disponíveis para cada solução foi realizado e as informações catalogadas. As soluções em questão foram localizadas

utilizando o motor de busca do Google. Ao final, os resultados foram consolidados e analisados com vistas a identificar as principais oportunidades para serem exploradas.

Cumpra salientar que determinadas informações, embora desejadas, não foram localizadas nas *páginas Web* das soluções mapeadas – uma vez que elas podem revelar detalhes sensíveis sobre como cada solução é implementada. Por exemplo, métodos de previsão utilizados, arquiteturas implementadas, *hardware/software/plataformas* utilizadas e ainda estratégias para extração de características dos dados (*feature engineering*). Portanto, este aspecto pode ser visto como uma limitação deste trabalho.

3.2 Resultados levantamento

Como resultado do levantamento, foram catalogadas 11 soluções diferentes de organizações do Brasil e internacionais. Observa-se que, no mercado, existem soluções com as mais diversas características e com foco em segmentos diversificados. Os resultados completos são apresentados no Quadro 1 abaixo.

Quadro 1 - Soluções disponíveis no mercado para a previsão de demanda.

	Nome	Casos de uso	Custo (S/N)	Características	Referência
1	PredictHQ	Turismo, aviação, supermercados, varejistas e transporte	S	Serviço de informações sobre eventos que podem afetar a demanda via API.	(PREDICTHQ, 2024)
2	AlgoPine	Varejistas em geral e comércio eletrônico	S	Serviço de previsão via API.	(ALGOPINE, 2024)
3	Remi	Varejistas, comércio eletrônico, manufatura e <i>e-commerce</i>	S	Serviço de previsão via API.	(REMI AI, 2024)
4	Unisoma	Agronegócios, varejistas, indústria de alimentos, indústria de calçados e frigorífico	S	Consultoria.	(UNISOMA, 2024)
5	Linear Softwares Matemáticos	Indústrias e serviços em geral	S	Consultoria.	(LINEAR, 2024)
6	Relex	Varejo, atacado, distribuição e bens de consumo	S	Plataforma completa com componente de previsão.	(RELEX, 2024)
7	AWS Marketplace	Mídia e entretenimento, indústria em geral, serviços financeiros, saúde e energia	S	Loja da AWS com diversas soluções de prateleira.	(AMAZON, 2024b)
8	IBM SPSS	-	S	Plataforma da IBM especializada em estatística.	(IBM, 2024)
9	Amazon Forecast	Varejo, turismo, atacado, eletrônicos	S	Plataforma da AWS com foco em previsão. Pode-se integrar via API.	(AMAZON, 2024a)

10	SAP S/4HANA	Peças de reposição	S	Plataforma SAP com foco no planejamento de peças de reposição.	(SAP, 2024)
11	Oracle® Retail Demand Planning	Varejo	S	Plataforma cloud da Oracle para o varejo. Possui módulo para previsão.	(ORACLE, 2024)

Fonte: Elaborado pelos autores.

No Quadro 1, a coluna “Casos de uso” apresenta os principais casos de uso reportados pelas soluções. A coluna “Característica” apresenta as principais características identificadas para cada solução. Pode-se observar uma ampla variedade de organizações no mercado oferecendo soluções em geral. Por exemplo, a solução 7 (AWS Marketplace) talvez seja a solução com maior alcance e número de produtos. Isto porque trata-se de uma plataforma em que desenvolvedores diversos podem hospedar as suas soluções, sendo o pagamento realizado mediante a utilização em horas na grande maioria dos casos.

Em quase todas elas, busca-se atender o varejo, sendo que apenas em 3 delas isto não ocorre, são elas: solução 5 (Linear Softwares Matemáticos), solução 8 (IBM SPSS) e solução 10 (SAP S/4HANA). É possível notar também que algumas soluções são baseadas em um serviço fornecido via *Application Programming Interface* (API), tal como acontece nas soluções 1, 2, 3 e 9. Isto significa que, do lado cliente, é necessário desenvolver algum *software* para fazer a integração com a API do provedor da solução, o que requer uma mão de obra especializada.

Existem outros casos também em que é possível utilizar uma plataforma, que já disponibiliza uma interface com usuário para utilização da ferramenta. Esta é uma vantagem pois não requer mão de obra especializada para a criação de integrações. Por exemplo, na solução 9 (*Amazon Forecast*), é possível fazer o *upload* de um arquivo no formato CSV padronizado e gerar as previsões a partir dele.


Por fim, deve-se destacar quem em todos os casos aqui apresentados existe alguma forma de ônus pela utilização. O modelo de precificação pode variar de organização para organização. Em alguns casos pode-se pagar pela utilização em horas. Adicionalmente, apenas uma solução encontrada possui especialização na indústria de peças de reposição, o que configura uma oportunidade para proposta de uma ferramenta que permita a execução de estudos de previsão de demanda. Além disto, não foram encontradas soluções no âmbito acadêmico que permitam o desenvolvimento e experimentação de novos modelos.

4. PROPOSTA FERRAMENTA

O levantamento introduzido na seção anterior serviu como base para o projeto e proposta da solução que se segue. O principal objetivo é construir uma aplicação que permita a execução de estudos de previsão de demandas no âmbito industrial e acadêmico. Adicionalmente, deve-se permitir a experimentação, testes e integração de novos métodos de previsão à ferramenta, com vistas a garantir a entrega de uma solução atualizada com o estado da arte na literatura.

Para isto, será criada uma interface Web utilizando a estratégia de *Single Page Application* (SPA) (MOZILLA FOUNDATION, 2024). A principal ideia do SPA é disponibilizar uma página Web em que um único formulário é carregado, sendo que apenas parte do conteúdo é atualizada sob demanda. A motivação por trás desta escolha é conferir simplicidade de uso a solução, podendo atingir assim uma quantidade maior de usuários. Além disto, a aplicação será dividida em quatro componentes principais, conforme ilustra a Figura 2.

Figura 2: Diagrama de implantação da solução proposta.



Fonte: Elaborado pelos autores.


A Figura 2 apresenta como a solução será implantada. Nesta arquitetura, o usuário (User PC) acessa a página pelo navegador (*Browser*), isto é, ambiente onde todas as interações são realizadas. Uma vez solicitado um estudo, via Internet (*<<http over internet>>*), os dados são enviados para um servidor (*Application Server*) dedicado onde todo o processamento é realizado. Deve-se observar que o Docker será utilizado para dividir a aplicação em serviços especializados, cada um cumprindo responsabilidades específicas, sendo eles:

- *API Backend*: responsável por receber requisições de estudos de previsão do SPA e direcionar o processamento para o container de processamento,
- *SPA*: responsável por hospedar a página Web, interface com o usuário,

- *Relational Database*: responsável por armazenar dados da ferramenta, tais como cadastros de usuários e informações sobre os estudos, e
- *Worker*: responsável por executar tarefas com operações intensivas de CPU e memória (treinamento de modelos, processamento de dados etc.).

Na solução proposta, um estudo será realizado de maneira isolada, considerando os arquivos de dados fornecidos pelo usuário. Finalizado o estudo, os recursos alocados são liberados para o próximo estudo na fila. No que diz respeito ao estudo, a Figura 3 apresenta um diagrama de sequência das atividades realizadas do lado do servidor (*Application Server*).

Figura 3: Diagrama de sequência da solução proposta.



Fonte: Elaborado pelos autores.

No diagrama de sequência da Figura 3 os principais objetos de controle do estudo são apresentados. Será executado um *pipeline* específico cuja sequência de atividades é controlada por um objeto *PipelineManager* que, por sua vez, recebe os dados de um estudo da API. Na primeira etapa, serão executadas atividades de limpeza de dados, isto é, manipulação de valores faltantes bem como *outliers* (pelo objeto *DataCleaner*). Tais técnicas são bastante úteis pois

ajudam a reduzir potenciais impactos no treinamento dos modelos. Na sequência, uma chamada ao método *compute_features* é realizada com o objetivo de extrair características das séries temporais. Algumas estratégias serão aplicadas conforme propostas realizadas por (LOLLI *et al.*, 2017).

Em seguida, atividades de transformação de dados serão realizadas com objetivo de produzir diferentes versões das informações e abrir a possibilidade para a experimentação de diferentes modelos. Tais atividades podem ser divisão de conjuntos de treinamento e teste, reamostragem, inclusão de variáveis externas (feriados, eventos locais etc.), agregação temporal entre outros. Todas controladas pelo objeto *DataTransformer*. Finalmente, o treinamento dos modelos e a geração das previsões serão controladas pelo objeto *ModelsManager*. Esta é uma parte de extrema importância da ferramenta pois concentra, possivelmente, as operações com maior sobrecarga de CPU e memória RAM. Além disso, o banco de dados relacional (componente *Relational Database*) armazena os dados dos estudos realizados. Isto porque tais bases servirão para o desenvolvimento, experimentação e inclusão de novos modelos. Tais etapas serão implementadas em um *pipeline* específico dentro da solução final.

Naturalmente, existem alguns desafios ao se implementar e manter esse tipo de arquitetura. Por exemplo, se um número elevado de estudos for solicitado ao mesmo tempo, isto pode gerar uma fila de espera demasiadamente longa para o usuário final. Adicionalmente, o uso de técnicas de aprendizado de máquina pode acarretar o consumo de muitos recursos de *hardware*. No entanto, é possível contornar tais desafios com a criação de *workers* dedicados para cada estudo, uso de modelos pré-treinados e ainda com a aplicação de técnicas de redução de dimensionalidade.

5. CONSIDERAÇÕES FINAIS

Problemas de previsão de demanda na indústria são de interesse acadêmico e comercial pois, previsões assertivas, podem levar a melhorias consideráveis no resultado financeiro em alguns setores da economia (por exemplo, do setor automotivo no Brasil) e auxiliar no desenvolvimento de pesquisas nesta área. Desse modo, pesquisadores interessados no tema têm proposto diferentes métodos de previsão e diversas empresas implementando-os em soluções de prateleira ou customizando em alguma forma de consultoria especializada. Em alguns casos é possível também fazer integrações com *softwares* de *Enterprise Resource Planning* (ERP), o que confere maior velocidade e automação no processo de tomada de decisão.

Neste estudo, os resultados do levantamento indicaram uma oportunidade de criação de um ambiente de experimentação e estudos de previsão utilizando ferramentas totalmente *open source*. A expectativa com o desenvolvimento e implementação no ambiente acadêmico é de disponibilizar uma solução sem custo. Com isto, espera-se atingir um público maior de estudantes e profissionais tendo que lidar com problemas de previsão, devida a simplicidade de uso da ferramenta e possibilidade de integração de novos modelos.

Desta forma, espera-se obter uma plataforma de experimentação colaborativa entre estudantes e profissionais, que permita integrar dados reais e a pesquisa acadêmica, viabilizando assim o avanço no estado da arte dos métodos de previsão de demanda, a aplicação prática dos modelos e potencialização dos processos de tomada de decisão dentro das organizações.

REFERÊNCIAS

- ALGOPINE. Algotpine. Disponível em: <<https://algotpine.com/>>. Acesso em: 2 abr. 2024.
- AMAZON Web Services. Amazon Forecast. Disponível em: <<https://aws.amazon.com/pt/forecast/>>. Acesso em: 3 abr. 2024.
- AMAZON Web Services. AWS Marketplace. Disponível em: <<https://aws.amazon.com/marketplace>>. Acesso em: 10 abr. 2024.
- ARMSTRONG, J. SCOTT (Org.). **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Boston, MA: Springer US, 2001. (International Series in Operations Research & Management Science). Disponível em: <<http://link.springer.com/10.1007/978-0-306-47630-3>>. Acesso em: 13 jun. 2024.
- BABAI, M.Z.; DALLERY, Y.; BOUBAKER, S.; KALAI, R. **A new method to forecast intermittent demand in the presence of inventory obsolescence**. International Journal of Production Economics, v. 209, p. 30–41, 2019.
- BATALHA, MÁRIO OTÁVIO (Org.). **Introdução à engenharia de produção**. Rio de Janeiro, Brasil: Elsevier, 2008.
- CHIEN, CHEN-FU; KU, CHIEN-CHUN; LU, YI-YUN. **Ensemble learning for demand forecast of After-Market spare parts to empower data-driven value chain and an empirical study**. Computers & Industrial Engineering, v. 185, p. 109670, 2023.
- COSTANTINO, FRANCESCO; DI GRAVIO, GIULIO; PATRIARCA, RICCARDO; PETRELLA, LEA. **Spare parts management for irregular demand items**. Omega, v. 81, p. 57–66, 2018.
- CROSTON, J. D. **Forecasting and Stock Control for Intermittent Demands**. Operational Research Quarterly (1970-1977), v. 23, n. 3, p. 289, 1972.
- DAUDT, GABRIEL MARINO; WILLCOX, LUIZ DANIEL. **Indústria automotiva =**

Automotive industry. Em: PUGA, FERNANDO PIMENTEL; CASTRO, LAVÍNIA BARROS DE (Org.). Visão 2035: **Brasil, país desenvolvido: agendas setoriais para alcance da meta.** 1. ed. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2018. p. 183-208.

FAGHIDIAN, S. FATEMEH; KHASHEI, MEHDI; KHALILZADEH, MOHAMMAD. **Improving intermittent demand forecasting based on data structure.** Journal of Engineering Research, v. 9, n. 1, 2021.

FILDES, ROBERT; PETROPOULOS, FOTIOS. **Simple versus complex selection rules for forecasting many time series.** Journal of Business Research, v. 68, n. 8, p. 1692–1701, 2015.

HYNDMAN, R.J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**, 3rd edition, OTexts: Melbourne, Australia. Disponível em: <<https://otexts.com/fpp3/counts.html>>. Acesso em: 15 jun. 2024.

IBM. IBM SPSS Statistics. Disponível em: <<https://www.ibm.com/br-pt/spss>>. Acesso em: 5 abr. 2024.

KIM, JAE-DONG; KIM, TAE-HYEONG; HAN, SUNG WON. **Demand Forecasting of Spare Parts Using Artificial Intelligence: A Case Study of K-X Tanks.** Mathematics, v. 11, n. 3, p. 501, 2023.

LI, XIONG; ZHAO, XIAODONG; PU, WEI. **Battle damage-oriented spare parts forecasting method based on wartime influencing factors analysis and ε -support vector regression.** International Journal of Production Research, v. 58, n. 4, p. 1178-1198, 2020.

LINEAR Software. Demand Forecast. Disponível em: <<https://www.linearsm.com.br/en/demand-forecast/>>. Acesso em: 8 abr. 2024.

LOLLI, F.; GAMBERINI, R.; REGATTIERI, A.; BALUGANI, E.; GATOS, T.; GUCCI. **Single-hidden layer neural networks for forecasting intermittent demand.** International Journal of Production Economics, v. 183, p. 116–128, 2017.

MAKRIDAKIS, SPYROS; SPILIOTIS, EVANGELOS; ASSIMAKOPOULOS, VASSILIOS. **M5 accuracy competition: Results, findings, and conclusions.** International Journal of Forecasting, v. 38, n. 4, p. 1346–1364, 2022.

MOZILLA FOUNDATION. SPA - **Single-page application.** MDN Web Docs. Disponível em: <https://developer.mozilla.org/en-US/docs/Glossary/SPA>. Acesso em: 15 jun. 2024.

ORACLE. Oracle Retail Demand Planning. Disponível em: <<https://www.oracle.com/br/retail/demand-planning/>>. Acesso em: 2 jul. 2024.

PREDICTHQ. PredictHQ. Disponível em: <<https://www.predicthq.com/>>. Acesso em: 8 abr. 2024.

RELEX Solutions. RELEX Solutions. Disponível em: <<https://www.relexsolutions.com/>>. Acesso em: 11 abr. 2024.

REMI AI. Demand Forecasting. Disponível em: <<https://www.remi.ai/demandforecasting>>. Acesso em: 6 abr. 2024.

SAP. Extended Service Parts Planning (SPP). Disponível em: <<https://www.sap.com/brazil/products/scm/extended-service-parts-planning.html>>. Acesso em: 6 abr. 2024.

UNISOMA. Prognos. Disponível em: <<https://www.unisoma.com.br/prognos/>>. Acesso em: 4 abr. 2024.

YANG, YOUPENG; DING, CHENYI; LEE, SANGHYUK; YU, LIMIN; MA, FEI. **A modified Teunter-Syntetos-Babai method for intermittent demand forecasting**. Journal of Management Science and Engineering, v. 6, n. 1, p. 53–63, 2021.

ZHANG, G. PETER; XIA, YUSEN; XIE, MAOHUA. **Intermittent demand forecasting with transformer neural networks**. Annals of Operations Research, 2023. Disponível em: <<https://link.springer.com/10.1007/s10479-023-05447-7>>. Acesso em: 30 jan. 2024.