

FELIPE MAIA VASSALO
VITOR CABEDA DE FARIA CASTRO

Sistema de apoio à decisão para planejamento da produção baseado em previsão de demanda: estudo de caso aplicado em uma empresa de manufatura moveleira

PROJETO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO
APRESENTADO AO DEPARTAMENTO DE ENGENHARIA INDUSTRIAL
DA PUC-RIO, COMO PARTE DOS REQUISITOS PARA OBTENÇÃO
DO TÍTULO DE ENGENHEIRO DE PRODUÇÃO

Orientador: Rodrigo Goyannes Gusmão Caiado

Co-orientador: Renan Silva Santos

Departamento de Engenharia Industrial
Rio de Janeiro, 24 de novembro de 2025.

AGRADECIMENTOS

Agradecemos, primeiramente, às nossas famílias por acreditarem em nós ao longo de toda esta jornada. Seu apoio constante foi essencial para que conseguíssemos superar os desafios e concluir este trabalho com dedicação e serenidade.

Aos amigos que fizemos durante nossa trajetória universitária, expressamos nossa profunda gratidão. Cada conversa, parceria, incentivo e experiência compartilhada contribuíram de forma significativa para o nosso crescimento pessoal e profissional.

Estendemos nossos agradecimentos aos funcionários da PUC-Rio e, em especial, às equipes do Departamento de Engenharia Industrial, por proporcionarem um ambiente acadêmico acolhedor, enriquecedor e com todos os recursos necessários para o desenvolvimento desta pesquisa.

Por fim, agradecemos aos nosso orientador, Rodrigo Caiado e coorientador, Renan Santos, por todo o apoio, disponibilidade e pelas valiosas orientações ao longo da elaboração deste trabalho. A dedicação e paciência de vocês foram fundamentais para que pudéssemos evoluir e aprimorar cada etapa deste TCC.

RESUMO

Este trabalho desenvolve um artefato computacional para apoio à decisão no planejamento da produção, integrando modelos de previsão de demanda a ferramentas clássicas de Planejamento e Controle da Produção (PCP), com foco em uma empresa real do setor moveleiro escolar. A pesquisa, conduzida sob a metodologia *Design Science Research* (DSR), parte da identificação de limitações na prática atual da organização, cuja tomada de decisão era fortemente baseada na experiência dos gestores e pouco apoiada em dados estruturados. Para endereçar essa lacuna, foi concebida uma solução capaz de processar séries temporais, gerar previsões, calcular o *Master Production Schedule* (MPS) e avaliar impactos em estoques, capacidade produtiva e custos operacionais.

O artefato desenvolvido estrutura-se em módulos integrados, abrangendo desde o *upload* e análise exploratória da série temporal até a geração automática da previsão, cálculo do MPS, análise de custo relevante total e diagnósticos visuais consolidados em um painel gerencial. A solução incorpora modelos estatísticos e de machine learning, explorando diferentes configurações de hiperparâmetros para selecionar o modelo mais adequado com base em métricas de acurácia. As previsões resultantes abastecem o módulo de PCP, que calcula estoques projetados, tamanhos de lote, início de ordens e ATP (*Available to Promise*), permitindo a simulação de cenários operacionais.

A aplicação do artefato em dados reais da empresa demonstrou sua utilidade prática ao permitir maior previsibilidade da demanda, melhor organização das ordens de produção e diagnóstico de *trade-offs* entre custos de setup, manutenção e ruptura. Foram também conduzidas análises de sensibilidade que permitiram avaliar a resposta do sistema a variações de parâmetros produtivos e econômicos, reforçando a robustez do modelo. Por fim, o artefato foi avaliado por especialistas da empresa, que destacaram sua relevância prática, facilidade de uso e potencial de expansão para outros produtos e setores internos. Os resultados obtidos evidenciam que a integração entre previsão de demanda e PCP, mediada por uma ferramenta computacional interativa, que contribui de forma significativa para a tomada de decisões mais precisas e alinhadas às necessidades reais de negócio.

Palavras-chave: Previsão de demanda; PCP; MPS; *Machine Learning*; Séries temporais; *Design Science Research*.

ABSTRACT

This work develops a computational artifact to support decision-making in production planning, integrating demand-forecasting models with classical Production Planning and Control (PPC) tools, with a focus on a real company in the school furniture sector. The research, conducted under the Design Science Research (DSR) methodology, begins with the identification of limitations in the organization's current practice, in which decision-making was strongly based on managerial experience and weakly supported by structured data. To address this gap, a solution was conceived capable of processing time series, generating forecasts, calculating the Master Production Schedule (MPS), and evaluating the impacts on inventory, production capacity, and operational costs.

The developed artifact is structured into integrated modules, ranging from uploading and exploratory analysis of the time series to automatic forecast generation, MPS calculation, total relevant cost analysis, and consolidated visual diagnostics in a managerial panel. The solution incorporates statistical and machine learning models, exploring different hyperparameter configurations to select the most suitable model based on accuracy metrics. The resulting forecasts feed the PPC module, which calculates projected inventories, lot sizes, order releases, and ATP (Available to Promise), enabling the simulation of operational scenarios.

The application of the artifact to real company data demonstrated its practical usefulness by enabling greater demand predictability, improved organization of production orders, and clearer diagnosis of trade-offs involving setup, holding, and stockout costs. Sensitivity analyses were also conducted to evaluate the system's response to variations in production and economic parameters, reinforcing the robustness of the model. Finally, the artifact was evaluated by company specialists, who highlighted its practical relevance, ease of use, and potential for expansion to other products and internal sectors. The results indicate that integrating demand forecasting and PPC through an interactive computational tool contributes significantly to more precise and business-aligned decision-making.

Key words: *Demand forecasting; PPC; MPS; Machine Learning; Time series; Design Science Research.*

SUMÁRIO

1 INTRODUÇÃO	9
2 REFERENCIAL TEÓRICO	12
2.1 Segmentação e Priorização de SKU's	12
2.1.1 Clusterização (K-means)	12
2.1.2 Curva ABC	12
2.2 Modelos de Previsão de Demanda: Clássicos e <i>Machine Learning</i>	13
2.2.1 Séries Temporais	13
2.2.1.1 Conceito de Série Temporal	13
2.2.1.2 Principais Características.....	13
2.2.2 Fundamentação Estatística	15
2.2.2.1 Conceitos estatísticos básicos.....	15
2.2.2.2 Propriedades e comportamentos das séries temporais.....	16
2.2.2.3 Avaliação Estatística das Séries Temporais	18
2.2.3 Transformação de Séries Temporais	22
2.2.3.1 Transformação Box-Cox	23
2.2.3.2 Transformação Logarítmica	24
2.2.4 Realizar previsões com séries temporais	24
2.2.4.1 Modelos de previsão	25
2.2.4.1.1 Modelos Clássicos	26
2.2.4.1.2 Modelos de Machine Learning	27
2.3 Planejamento da Produção: Impactos em Custos e Estoque.....	33
2.3.1 MPS	33
2.3.1.1 Estrutura e Funcionamento do MPS.....	34
2.3.2 Custos	35
2.3.3 Estoque de Segurança.....	36
3 METODOLOGIA.....	38
3.1 <i>Design Science Research</i> (DSR).....	38
3.2 Estrutura do DSR	39
3.3 Conscientização do Problema.....	39
3.3.1 Introdução: como o problema foi definido	39
3.3.2 Entendendo os prejuízos da problemática nas Empresas	40

3.4 Sugestão de Soluções	41
3.4.1 Pré-Processamento	43
3.4.2 Processamento	45
3.4.3 Pós-Processamento	46
3.5 Desenvolvimento do Artefato	47
3.5.1 Arquitetura Geral do Artefato.....	47
3.5.2 Descrição dos Módulos	48
3.5.3 Fluxos do Usuário.....	49
3.6 Avaliação do Artefato.....	51
3.7 Conclusão e Comunicação dos Resultados.....	51
4 RESULTADOS E DISCUSSÃO	53
4.1 Descrição do caso e da empresa	53
4.2 Aplicação do protótipo no caso	53
4.2.1 Antes do uso do artefato	54
4.2.2 Primeiros passos dentro do artefato.....	55
4.2.3 Resultados – Análise Série Temporal e Previsão	55
4.2.4 Resultados – Gestão de estoque	63
4.2.5 Resultados – Recomendações.....	66
4.3 Análise de sensibilidade	70
4.3.1 Sensibilidade aplicada ao MPS.....	71
4.3.2 Sensibilidade aplicada aos custos do MPS	74
4.3.3 Sensibilidade aplicada ao ATP Acumulado	77
4.4 Avaliação do protótipo com especialistas do caso.....	78
5 CONCLUSÕES.....	80
6 BIBLIOGRAFIA	82
7 APÊNDICE	88
7.1 Apêndice A – Código <i>Streamlit</i>.....	88
7.1 Apêndice B – Experimentos.....	88

LISTA DE FIGURAS

Figura 1: Classificação dos Padrões de Demanda Segundo os Valores de ADI e CV ²	20
Figura 2: Modelo de Registro MPS.....	34
Figura 3: Modelos de Registro MPS Vazio.....	34
Figura 4: Diagrama Prisma.....	42
Figura 5: Mapeamento do Fluxo do Artefato	50
Figura 6: Diagrama de Caso de Uso	50
Figura 7: Resultado da Clusterização	54
Figura 8: Resultado da Classificação ABC	54
Figura 9: Carregamento da Série Temporal	55
Figura 10: Análise Exploratória, Série Real x Série Artificial	56
Figura 11: Análise Gráfica, Série Real x Série Artificial	57
Figura 12: Identificação de Outliers, Série Real.....	57
Figura 13: Identificação de Outliers, Série Artificial	57
Figura 14: Análise Detalhada (Parte 2), Série Real x Série Artificial.....	58
Figura 15: Análise Detalhada (Parte 1), Série Real x Série Artificial.....	58
Figura 16: Análise Detalhada (Parte Final), Série Real x Série Artificial.....	59
Figura 17: Etapa de Previsão	61
Figura 18: Resultado das Previsões, Série Real x Série Artificial.....	61
Figura 19: Inputs Operacionais MPS – Cenário Base	63
Figura 20: Estoque de Segurança – Cenário Base	64
Figura 21: Congelamento de Horizonte – Cenário Base	64
Figura 22: Pedidos firmes – Cenário Base	64
Figura 23: Parâmetros de Custos – Cenário Base.....	65
Figura 24: Mensagem de Confirmação	65
Figura 25: MPS - Cenário Base.....	66
Figura 26: Real + Projetado - Cenário Base.....	67
Figura 27: Métricas de Desempenho da Previsão - Cenário Base.....	67
Figura 28: Painel com Informações sobre o Viés - Cenário Base	68
Figura 29: Gráfico Representando Viés da Série Temporal - Cenário Base.....	68
Figura 30: Custos do MPS - Cenário Base	69
Figura 31: ATP Acumulado	69
Figura 32: Painel de Controle dos Parâmetros	70
Figura 33: Custos da Simulação e Curva da Sensibilidade	70
Figura 34: MPS - Cenário 1	72
Figura 35: MPS - Cenário 2.....	73
Figura 36: MPS - Cenário 3.....	74
Figura 37: Custos MPS - Cenário 4.....	75
Figura 38: Custos MPS - Cenário 5.....	76
Figura 39: ATP - Cenário 7	78

LISTA DE EQUAÇÕES

Equação 1: Decomposição Aditiva da Série Temporal	14
Equação 2: Decomposição Multiplicativa da Série Temporal	14
Equação 3: Intervalo Interquartilico	15
Equação 4: Limite Inferior do Método Interquartilico	16
Equação 5: Limite Superior do Método Interquartilico.....	16
Equação 6: Equação de Autocorrelação	17
Equação 7: Força da Tendência em uma Série Temporal	18
Equação 8: Força da Sazonalidade em uma Série Temporal	18
Equação 9: Intervalo Médio entre Demandas.....	19
Equação 10: Coeficiente de Variação ao Quadrado	19
Equação 11: Teste de Shapiro-Wilk	21
Equação 12: Coeficiente de Assimetria.....	21
Equação 13: Transformação Box-Cox	23
Equação 14: Equações do Modelo Croston.....	27
Equação 15: Expressão do SBA	28
Equação 16: Equações do TSB.....	29
Equação 17: Algoritmo do Random Forest	30
Equação 18: Equações do LSTM	31
Equação 19: Fórmula do MAE.....	32
Equação 20: Fórmula do RMSE.....	32
Equação 21: Fórmula do MAPE.....	33
Equação 22: Fórmula do sMAPE	33
Equação 23: Cálculo do Estoque Projetado por Período.....	34
Equação 24: Cálculo do ATP por Período.....	35
Equação 25: Cálculo do Custo de Preparação (Setup)	35
Equação 26: Cálculo do Custo de Manter o Estoque	36
Equação 27: Cálculo do Custo Relevante Total no Modelo EOQ	36
Equação 28: Cálculo do Custo Relevante Total no Modelo EPQ	36
Equação 29: Cálculo Clássico do Estoque de Segurança	37
Equação 30: Cálculo do Estoque de Segurança Utilizando o Coeficiente de Variação	37

LISTA DE TABELAS

Tabela 1: Pesquisas e Strings de Busca	42
Tabela 2: Melhores resultados para cada modelo na série real	42
Tabela 3: Melhores resultados para cada modelo na série artificial	42

1 INTRODUÇÃO

A Indústria 4.0 tem impulsionado mudanças significativas nos sistemas produtivos, com destaque para a integração de tecnologias digitais, inteligência artificial e análise de dados como meios de apoiar decisões estratégicas. A competitividade em ambientes de manufatura exige maior precisão na previsão de demanda e maior eficiência na gestão de estoques, fatores essenciais para reduzir desperdícios, atender com confiabilidade e otimizar recursos (Babaï; Arampatzis, 2025).

No setor moveleiro, especialmente na fabricação de móveis escolares, esses desafios tornam-se ainda mais relevantes. A sazonalidade da demanda, marcada por períodos de pico como a volta às aulas, somada à diversidade de modelos e especificações, dificulta o planejamento da produção e compromete a adequação dos estoques. Em muitos casos, as decisões ainda são tomadas com base em métodos empíricos ou históricos simplificados, resultando em estoques excessivos ou insuficientes, que geram atrasos e perda de oportunidades de venda, impactando nível de serviço.

A literatura mostra que a aplicação de algoritmos de aprendizado de máquina, do inglês *machine learning* (ML) em previsão de demanda tem produzido ganhos significativos de acurácia e capacidade preditiva em cadeias produtivas complexas (DOUAILOUI et al., 2024; KHEDR et al., 2024). Quando combinada com ferramentas clássicas de Planejamento e Controle da Produção (PCP), como o Planejamento Mestre da Produção, do inglês *Master Production Schedule* (MPS). Essa abordagem contribui para um alinhamento mais eficiente entre oferta e demanda, ao conectar previsões de consumo a decisões de produção e abastecimento (Polo-triana, 2024; Sattar et al., 2025). Apesar desses avanços, diversos autores apontam que a aplicação prática de modelos de ML ainda ocorre de forma isolada, com baixa integração aos sistemas operacionais de PCP e gestão de estoques, o que mantém uma lacuna entre a geração de previsões e a execução dos planos mestres de produção (Lima et al., 2021; Goltsos, 2022; Maier, 2022). Essa limitação reforça a necessidade de desenvolver artefatos híbridos que combinem a precisão dos modelos preditivos baseados em dados com a estrutura decisória dos modelos clássicos de PCP, tornando possível converter previsões acuradas em ações operacionais concretas no MPS e no controle de estoques.

Diante desse cenário, emerge o seguinte problema de pesquisa (PP): **como desenvolver um modelo que converta previsões de demanda em decisões de planejamento e gestão de estoques, aumentando a eficiência e a confiabilidade operacional em uma empresa de manufatura moveleira?**

O estudo justifica-se, portanto, pela necessidade de aproximar os avanços teóricos sobre previsão e inteligência artificial da realidade de empresas do setor moveleiro. Do ponto de vista acadêmico, contribui ao propor uma abordagem integrada entre modelos de previsão baseados em Inteligência Artificial (IA) e ferramentas de PCP, campo em que ainda existem lacunas a serem exploradas. Sob a ótica prática, apresenta uma alternativa de apoio à decisão que pode resultar em redução de custos, maior confiabilidade nos prazos de entrega e maior alinhamento da produção às demandas de mercado.

O objetivo geral deste trabalho é desenvolver um modelo de apoio à decisão para o planejamento inteligente de operações em uma empresa de manufatura moveleira, integrando previsões de demanda a ferramentas de PCP. Como objetivos específicos, busca-se:

- (i) elaborar e comparar diferentes modelos de previsão de demanda com base em modelos clássicos e de ML;
- (ii) selecionar o modelo mais adequado à série temporal apresentada pelo usuário;
- (iii) integrar o modelo escolhido ao MPS, possibilitando integrar previsão com gestão de estoque;
- (iv) desenvolver uma interface que possibilite avaliação dos resultados para tomada de decisões;
- (v) Avaliar o desempenho do artefato quanto à precisão, usabilidade e impactos no PCP em um caso real;
- (vi) Aplicação de combinação de métodos de segmentação de SKU's com objetivo de trazer relevância a aplicação dentro do estudo de caso.

A pesquisa é de natureza aplicada e fundamenta-se na metodologia *Design Science Research* (DSR), que tem como propósito a construção e avaliação de artefatos voltados à solução de problemas reais com base em fundamentos científicos (Dresch; Lacerda; Antunes, 2015). O estudo busca desenvolver um artefato computacional de apoio à decisão que integre previsões de demanda obtidas por modelos de previsão à ferramenta clássica do Planejamento e Controle da Produção (MPS), que será validado através de um Estudo de Caso, empiricamente

e experimentalmente, através de conversas com especialistas da área e utilizando dados reais da empresa. A base de dados será extraída do sistema de gestão da empresa analisada, permitindo comparar modelos preditivos e incorporar o mais acurado ao artefato.

Do ponto de vista teórico, a pesquisa contribui para solucionar um *gap* evidente na literatura, através da combinação de modelos de previsão que utilizem da Inteligência Artificial e o uso de ferramentas clássicas de gestão de estoque e avaliação da produção. Sob a ótica prática, oferece às empresas um instrumento digital que apoia decisões operacionais de forma automatizada e baseada em dados reais de demanda. Em termos metodológicos, o estudo demonstra a aplicabilidade da DSR na criação de soluções híbridas que unem a atualidade, com modelos de ML, os métodos clássicos, já conhecidos e amplamente utilizados, com a gestão da produção.

Este trabalho está estruturado da seguinte forma: o Capítulo 1 apresenta a introdução, incluindo contexto, problema, objetivos e justificativa. O Capítulo 2 traz o referencial teórico, abordando os principais conceitos sobre as etapas de pré-processamento, processamento e pós-processamento que foram usadas no desenvolvimento do artefato. O Capítulo 3 descreve a metodologia aplicada, passando por todos os pontos do desenvolvimento do projeto. O Capítulo 4 apresenta os resultados e discussões sobre o protótipo criado e, por fim, o Capítulo 5 apresenta as conclusões do artefato desenvolvido.

2 REFERENCIAL TEÓRICO

2.1 Segmentação e Priorização de SKU's

2.1.1 Clusterização (K-means)

Clusterização é uma técnica de aprendizado não supervisionado utilizada para agrupar dados em conjuntos homogêneos, buscando maximizar a similaridade interna e minimizar a similaridade entre grupos (Beltrame; Fonseca, 2010). Essa abordagem é amplamente usada dentro de mineração de dados e análise preditiva, permitindo identificar padrões e tendências que auxiliam na tomada de decisão (IBM, 2023).

Entre os métodos existentes, o *K-means* se destaca por sua simplicidade e eficiência. O algoritmo divide o conjunto de dados em k grupos, atribuindo cada grupo ao centroide mais próximo e recalculando as médias até que os grupos se estabilizem (BELTRAME; FONSECA, 2010).

Nos últimos anos, a aplicação do *K-means* em engenharia de produção tem se expandido significativamente, impulsionada pela digitalização dos processos industriais e avanço da indústria 4.0.

2.1.2 Curva ABC

A Curva ABC é uma ferramenta amplamente utilizada na gestão de estoques por permitir a classificação dos itens conforme sua relevância econômica e operacional. Baseada no Princípio de Pareto, a metodologia identifica que uma pequena parcela dos itens responde pela maior parte do valor movimentado, agrupando-os em três categorias: A, de maior importância; B, intermediária; e C, de menor impacto no valor total (Dias, 2015).

Essa técnica possibilita aos gestores direcionarem seus esforços aos produtos mais significativos, otimizando o uso dos recursos e reduzindo custos operacionais (Ballou, 2006). A aplicação prática da ferramenta tem mostrado resultados expressivos. Em uma empresa do setor de combate a incêndio, a adoção da Curva ABC resultou em redução de 51% do capital investido em estoque, além de maior equilíbrio econômico e melhor utilização do espaço físico (Facchini; Silva; Leite, 2019). A técnica também contribui para a melhoria da eficiência logística e competitividade organizacional, evidenciando produtos com maior giro e lucratividade (Santa ana, 2021).

2.2 Modelos de Previsão de Demanda: Clássicos e *Machine Learning*

2.2.1 Séries Temporais

2.2.1.1 Conceito de Série Temporal

Uma série temporal é uma sequência de observações registradas em intervalos regulares cujo propósito é identificar padrões do passado e projetar comportamentos futuros. Essas séries costumam apresentar componentes como tendência, sazonalidade, nível e ruído, além de dependência temporal capturada por medidas como a autocorrelação. Ao tratá-las como processos estocásticos, é possível formalizar propriedades estatísticas — média, variância e covariâncias ao longo de defasagens — e distinguir padrões estruturais de flutuações aleatórias (Hyndman e Athanasopoulos, 2024).

No contexto industrial, séries temporais são fundamentais para identificar padrões ligados à demanda, produção, uso de máquinas e indicadores de qualidade. Sua análise permite otimizar recursos, aumentar a eficiência, antecipar flutuações e apoiar decisões em ambientes incertos. Em sistemas orientados por produção enxuta e dependente da demanda, previsões precisas são essenciais para reduzir estoques, evitar rupturas, manter o fluxo produtivo e garantir entregas confiáveis, reforçando a competitividade (Fatima e Rahimi, 2024).

2.2.1.2 Principais Características

Para compreender o comportamento de uma série temporal e interpretar corretamente seus padrões, é essencial reconhecer as características que definem sua estrutura ao longo do tempo. Cada série apresenta um conjunto próprio de propriedades que refletem o fenômeno estudado — algumas podem demonstrar uma tendência de crescimento ou queda, enquanto outras exibem padrões que se repetem periodicamente, ou ainda flutuações aleatórias sem regularidade aparente. A identificação desses elementos é fundamental para a escolha adequada do modelo de previsão e para a extração de informações relevantes sobre a dinâmica temporal dos dados (Hyndman e Athanasopoulos, 2024).

A tendência representa o movimento de longo prazo da série, indicando crescimento, queda ou mudança estrutural ao longo do tempo. Ela não precisa ser linear e pode variar de direção em diferentes períodos. Identificá-la é fundamental, pois orienta a forma como os modelos são ajustados e interpretados. A sazonalidade corresponde a padrões que se repetem

em intervalos regulares, como meses, estações ou dias, geralmente associados a hábitos de consumo, clima ou eventos do calendário. Esse comportamento recorrente, como o aumento típico das vendas no Natal, precisa ser capturado pelo modelo para melhorar a precisão das previsões. O ruído, por sua vez, representa a parcela aleatória da série: variações irregulares e imprevisíveis que não seguem nenhum padrão estrutural. Ele decorre de choques momentâneos e fatores externos. Um bom modelo deve isolar esse componente, deixando resíduos essencialmente aleatórios e sem autocorrelação, indicando que toda a informação sistemática foi explicada (Hyndman e Athanasopoulos, 2024).

Além disso, essas características representam os componentes fundamentais de uma série temporal. Para compreendê-los de forma mais detalhada e aplicá-los adequadamente aos modelos de previsão, é comum decompor a série em partes separadas, analisando individualmente o comportamento de cada uma. Essa decomposição permite distinguir a tendência, a sazonalidade e o ruído de forma mais clara, facilitando a interpretação dos padrões. A decomposição pode ser feita de forma aditiva ou multiplicativa, dependendo da relação entre as componentes e o nível da série. O modelo aditivo é mais apropriado quando a magnitude das flutuações sazonais e das variações ao redor da tendência não varia com o nível da série temporal. Já o modelo multiplicativo é mais indicado quando a variação sazonal ou cíclica é proporcional ao nível da série, o que é comum em séries econômicas (Hyndman e Athanasopoulos, 2024).

Matematicamente, a decomposição aditiva e multiplicativa pode ser representada da seguinte forma:

$$y_t = S_t + T_t + R_t$$

Equação 1: Decomposição Aditiva da Série Temporal

$$y_t = S_t \times T_t \times R_t$$

Equação 2: Decomposição Multiplicativa da Série Temporal

Por fim, a frequência de uma série temporal — isto é, o intervalo entre as observações, como diário, semanal, mensal ou anual — influencia diretamente o tipo de padrão que pode ser identificado e o horizonte de previsão possível. Séries com maior granularidade (como diárias ou horárias) tendem a capturar flutuações rápidas e comportamentos sazonais de curto prazo,

enquanto séries agregadas em períodos mais longos (mensais ou anuais) destacam tendências estruturais de maior duração. A escolha da frequência deve ser coerente com o objetivo da análise e com a disponibilidade de dados, garantindo a consistência temporal necessária para a aplicação de modelos de previsão confiáveis. No contexto industrial, manter uma frequência adequada e constante é fundamental para identificar variações reais de desempenho e evitar conclusões distorcidas sobre a demanda ou a produção (Hyndman e Athanasopoulos, 2024).

2.2.2 Fundamentação Estatística

2.2.2.1 Conceitos estatísticos básicos

Antes da aplicação de métodos de previsão em séries temporais, é essencial compreender conceitos estatísticos fundamentais que possibilitam interpretar o comportamento dos dados e identificar irregularidades. As medidas, como média, mediana, variância e desvio padrão são amplamente utilizadas para descrever o centro e a dispersão de uma distribuição. A média representa o valor médio das observações, enquanto a mediana expressa o ponto central da amostra, sendo menos sensível à influência de valores extremos. A variância e o desvio padrão, por sua vez, quantificam o grau de dispersão em torno da média, indicando o quanto os dados se afastam de seu comportamento típico. O exame prévio dessas medidas permite identificar anomalias e compreender se a série apresenta comportamento estável ou variações que demandam tratamento específico (Montgomery; Runger, 1994).

Uma das abordagens mais utilizadas para a identificação de valores atípicos é o método do intervalo interquartil, do inglês *Interquartile Range* (IQR), que se baseia nos quartis da distribuição dos dados. O primeiro quartil (Q1) corresponde ao ponto em que 25% das observações estão abaixo, e o terceiro quartil (Q3) indica o ponto em que 75% estão abaixo. O intervalo interquartil é então calculado como a diferença entre esses dois valores, servindo como medida robusta de dispersão para detectar possíveis *outliers* (Montgomery; Runger, 1994).

$$IQR = Q_3 - Q_1$$

Equação 3: Intervalo Interquartilico

A partir do intervalo interquartil, definem-se os limites para a identificação de valores atípicos, do inglês *outliers*, que correspondem a observações que se distanciam significativamente do padrão central dos dados. Para determinar esses limites, considera-se que

um valor é classificado como *outlier* moderado quando está acima do limite superior (LS) ou abaixo do limite inferior (LI) obtidos a partir do intervalo interquartil. As fórmulas correspondentes são apresentadas a seguir. Essa metodologia auxilia na detecção de observações discrepantes, permitindo a limpeza e preparação adequada das séries temporais antes da modelagem, o que contribui para análises mais consistentes e previsões mais precisas (Montgomery; Runger, 1994).

$$LI = Q_3 - 1,5 \times IQR$$

Equação 4: Limite Inferior do Método Interquartil

$$LS = Q_3 + 1,5 \times IQR$$

Equação 5: Limite Superior do Método Interquartil

2.2.2.2 Propriedades e comportamentos das séries temporais

Para a construção de modelos de previsão consistentes e adequados, é fundamental realizar uma análise aprofundada das propriedades estatísticas das séries temporais. Essa etapa permite compreender como os dados se comportam ao longo do tempo, identificando aspectos como estabilidade, dependência entre observações e variações de dispersão. A avaliação dessas características é essencial para selecionar transformações e métodos de modelagem coerentes com o tipo de série em estudo, evitando erros de especificação e garantindo resultados mais precisos (Hyndman e Athanasopoulos, 2024).

A estacionariedade ocorre quando as propriedades estatísticas de uma série temporal não dependem do momento em que são observadas, ou seja, quando a média, a variância e a covariância permanecem constantes ao longo do tempo. Séries que apresentam tendência ou sazonalidade não são estacionárias, pois esses componentes fazem com que o comportamento da série se altere de forma sistemática entre os períodos. Já séries compostas apenas por ruído branco — flutuações aleatórias sem padrão — são estacionárias, visto que mantêm variabilidade constante e ausência de dependência temporal. Em alguns casos, séries com comportamento cíclico, mas sem tendência definida, também podem ser consideradas estacionárias, desde que os ciclos não possuam periodicidade fixa. Quando a série não apresenta estacionariedade, é comum aplicar técnicas de diferenciação (Δ), que removem tendências e tornam a série adequada para modelos baseados nesse pressuposto, como o ARIMA e suas variações (Hyndman e Athanasopoulos, 2024).

A autocorrelação é uma medida estatística que avalia o grau de dependência entre os valores atuais de uma série temporal e seus valores passados, também chamados de *lags*. Cada *lag* representa o número de períodos de defasagem entre duas observações sucessivas da série, sendo o *lag* 1 a comparação entre y_t e y_{t-1} , o *lag* 2 entre y_t e y_{t-2} , e assim por diante. Valores de autocorrelação próximos de 1 indicam forte dependência entre os períodos, enquanto valores próximos de 0 sugerem comportamento aleatório, característico de um ruído branco. Essa medida é fundamental para identificar padrões de persistência nos dados e auxiliar na escolha de modelos adequados de previsão. A fórmula utilizada para o cálculo da autocorrelação é apresentada a seguir (Hyndman e Athanasopoulos, 2024).

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y}) \times (y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}$$

Equação 6: Equação de Autocorrelação

A heterocedasticidade ocorre quando a variância de uma série temporal não permanece constante ao longo do tempo, indicando que os valores apresentam flutuações de amplitude variável entre os períodos. Em outras palavras, a dispersão dos dados depende do momento observado, o que reflete instabilidade na variabilidade da série. Esse comportamento é comum em séries econômicas e financeiras, que apresentam períodos de maior e menor volatilidade. Já a homocedasticidade caracteriza séries em que a variância é constante, tornando o comportamento dos erros mais previsível e adequado à aplicação de modelos estatísticos tradicionais. Identificar a presença de heterocedasticidade é essencial para definir transformações e métodos que estabilizem a variância e garantam a coerência dos resultados obtidos (Ashley, 2012).

É possível também avaliar a intensidade dos componentes de tendência e sazonalidade presentes em uma série temporal, o que auxilia na compreensão do seu comportamento e na escolha dos modelos de previsão mais adequados. A partir da decomposição STL, a série é separada em três partes: tendência (T_t), sazonalidade (S_t) e resíduo (R_t). Com base nessa estrutura, pode-se mensurar o quanto a série é explicada pela tendência e o quanto é explicada pela sazonalidade, utilizando medidas conhecidas como força da tendência (F_T) e força da sazonalidade (F_S). Esses indicadores variam entre 0 e 1, sendo valores próximos de 1 associados a séries com forte tendência ou sazonalidade, e valores próximos de 0 a séries que apresentam

comportamento mais aleatório. As fórmulas utilizadas para o cálculo dessas medidas são apresentadas a seguir (Hyndman e Athanasopoulos, 2024).

$$F_T = \max\left(0, 1 - \frac{Var(R_t)}{Var(T_t + R_t)}\right)$$

Equação 7: Força da Tendência em uma Série Temporal

$$F_S = \max\left(0, 1 - \frac{Var(R_t)}{Var(S_t + R_t)}\right)$$

Equação 8: Força da Sazonalidade em uma Série Temporal

2.2.2.3 Avaliação Estatística das Séries Temporais

Para compreender adequadamente o comportamento de uma série temporal e garantir a aplicação correta dos modelos de previsão, é fundamental realizar testes estatísticos e análises gráficas que permitam identificar suas principais características. Essa etapa possibilita verificar se a série apresenta propriedades como estacionariedade, homocedasticidade, normalidade dos resíduos e autocorrelação, além de avaliar a presença de tendências ou padrões sazonais. A combinação entre testes formais e inspeção visual fornece uma base sólida para a avaliação estatística da série, permitindo selecionar métodos e transformações que melhor representem seu comportamento real e assegurem maior precisão nas previsões.

Para identificar as características de intermitência de uma série temporal e classificá-la conforme o padrão de ocorrência de sua demanda, são utilizadas duas métricas principais: o Intervalo Médio entre Demandas, do inglês *Average Inter-Demand Interval* (ADI) e o Coeficiente de Variação ao Quadrado, do inglês *Squared Coefficient of Variation* (CV²). O ADI representa o intervalo médio entre dois períodos consecutivos com ocorrência de demanda, enquanto o CV² mede a variabilidade relativa dos tamanhos das demandas não nulas. Esses indicadores permitem distinguir séries contínuas de séries intermitentes, caracterizando o grau de irregularidade dos dados. Valores elevados de ADI indicam longos períodos sem demanda, enquanto altos valores de CV² refletem grande variação entre as quantidades demandadas. A combinação desses parâmetros possibilita identificar o tipo de comportamento da série e definir o método de previsão mais apropriado. As fórmulas correspondentes ao cálculo do ADI e do CV² são apresentadas a seguir (Kaya, Sahin e Demirel, 2020).

$$ADI = \frac{\sum_{i=1}^N t_i}{N}$$

Equação 9: Intervalo Médio entre Demandas

$$CV^2 = \left(\frac{\sqrt{\sum_{i=1}^N (e_i - \bar{e})^2}}{\bar{e}} \right)$$

Equação 10: Coeficiente de Variação ao Quadrado

onde t_i representa o tempo entre duas demandas consecutivas, e_i o valor da demanda no período, \bar{e} a média das demandas não nulas e N o número total de períodos analisados.

A combinação entre as métricas ADI e CV^2 permite classificar as séries de demanda em quatro categorias distintas, de acordo com a frequência e a variabilidade das ocorrências. Quando os valores de ADI e CV^2 são baixos, a série é classificada como suave (*smooth*), indicando que as demandas ocorrem frequentemente e apresentam baixa variação entre os períodos. Séries com ADI alto e CV^2 baixo são denominadas intermitentes (*intermittent*), pois apresentam longos intervalos sem demanda, mas com quantidades relativamente estáveis quando ocorrem. Já as séries com ADI baixo e CV^2 alto são consideradas erráticas (*erratic*), caracterizadas por ocorrências regulares, porém com tamanhos de demanda muito variáveis. Por fim, séries com valores elevados de ADI e CV^2 são classificadas como irregulares ou instáveis (*lumpy*), refletindo longos períodos sem demanda e volumes altamente imprevisíveis quando ocorrem (Kaya, Sahin e Demirel, 2020).

Essas quatro classificações podem ser visualizadas graficamente por meio de um diagrama de quadrantes, no qual o eixo horizontal representa o ADI e o eixo vertical o CV^2 . Esse gráfico facilita a identificação do comportamento da série e auxilia na seleção do modelo de previsão mais adequado para cada tipo de padrão, permitindo uma análise mais assertiva do grau de intermitência (Kaya, Sahin e Demirel, 2020).




Figura 1: Classificação dos Padrões de Demanda Segundo os Valores de ADI e CV^2

Fonte: Kaya, Sahin e Demirel (2020).

Para verificar se uma série apresenta homocedasticidade — isto é, variância constante dos erros — ou heterocedasticidade, é comum aplicar o teste de Breusch–Pagan, também conhecido como *Lagrange Multiplier test* (LM). Esse procedimento testa a hipótese nula (H_0) de homocedasticidade, segundo a qual a variância dos resíduos é constante, contra a hipótese alternativa (H_1), que indica a presença de heterocedasticidade, isto é, variância dependente das variáveis explicativas. O teste consiste em estimar uma regressão auxiliar dos resíduos ao quadrado sobre as variáveis independentes e calcular o estatístico LM, que segue uma distribuição qui-quadrado com graus de liberdade iguais ao número de regressores incluídos. Caso o valor do estatístico exceda o ponto crítico da distribuição, rejeita-se H_0 , concluindo-se que há evidências de heterocedasticidade. Dessa forma, o teste permite identificar se a série possui variância constante ou variância crescente e instável, auxiliando na escolha de transformações adequadas, como log ou Box–Cox, para estabilizar a variância (Greene, 2018).

A heterocedasticidade condicional foi introduzida por Engle (1982) em seu modelo *Autoregressive Conditional Heteroscedasticity* (ARCH), no qual demonstrou que a variância dos erros em uma série temporal pode variar ao longo do tempo e depender de valores passados da própria série. Essa característica reflete a presença de períodos consecutivos de alta ou baixa variabilidade, especialmente comuns em séries econômicas e financeiras. De forma conceitual, o autor mostra que a variância condicional aumenta conforme o nível da série cresce, indicando que a dispersão dos dados não é constante. Esse comportamento pode ser identificado empiricamente pela relação positiva entre o nível médio e o desvio padrão da série, sugerindo

que a variância cresce junto com o nível — sintoma típico de heterocedasticidade condicional (Engle, 1982).

O teste de Shapiro–Wilk, proposto originalmente por Shapiro e Wilk (1965), é um dos métodos mais reconhecidos para avaliar a normalidade de uma amostra. Sua formulação baseia-se na correlação entre os dados observados e os valores esperados de uma distribuição normal teórica, sendo calculado por meio da razão entre a variância explicada pelos quantis esperados e a variância total amostral. O estatístico SW varia entre 0 e 1, onde valores próximos de 1 indicam alta aderência à normalidade. Teoricamente, o teste verifica se a ordenação dos dados e suas covariâncias correspondem às de uma distribuição normal padrão, o que o torna altamente sensível a desvios de assimetria e curtose.

$$SW = \frac{(\sum_{i=1}^n a_i X_{(i)})^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

Equação 11: Teste de Shapiro-Wilk

A avaliação da assimetria pode ser realizada por meio do coeficiente de assimetria (a_3), que quantifica o grau e o sentido de afastamento de uma distribuição em relação à simetria. De acordo com Costa Neto (2002), essa medida é obtida pelo quociente entre o momento centrado de terceira ordem (m_3) e o cubo do desvio padrão (s^3), conforme a expressão apresentada a seguir:

$$a_3 = \frac{m_3}{s^3}$$

Equação 12: Coeficiente de Assimetria

Essa fórmula gera uma medida adimensional, permitindo comparações entre diferentes conjuntos de dados. Valores positivos de a_3 indicam assimetria positiva, ou seja, distribuições alongadas à direita, enquanto valores negativos indicam assimetria negativa, com cauda alongada à esquerda. Quando o coeficiente é próximo de zero, considera-se a distribuição aproximadamente simétrica (Costa Neto, 2002).

O teste de Dickey–Fuller Aumentado (ADF) é um teste de hipótese desenvolvido para verificar a presença de raiz unitária em séries temporais, sendo amplamente utilizado para avaliar a estacionariedade dos dados. A hipótese nula (H_0) assume que a série possui raiz

unitária e, portanto, não é estacionária, enquanto a hipótese alternativa (H_1) sugere que a série é estacionária. O teste baseia-se na estimação de um modelo autorregressivo, avaliando se o coeficiente associado ao termo defasado é estatisticamente diferente de zero. A versão aumentada (ADF) proposta por Dickey e Fuller (1979) inclui defasagens adicionais das diferenças da variável dependente para corrigir autocorrelações nos resíduos, tornando o teste mais robusto para séries reais. Assim, o ADF permite identificar se as flutuações da série decorrem de choques transitórios (estacionária) ou permanentes (não estacionária), sendo uma das ferramentas fundamentais na análise de séries temporais.

O teste de Kwiatkowski–Phillips–Schmidt–Shin (KPSS), por sua vez, foi desenvolvido como um complemento ao teste ADF, invertendo suas hipóteses para uma análise mais abrangente da estacionariedade. Nesse teste, a hipótese nula (H_0) assume que a série é estacionária — ou seja, possui média e variância constantes ao longo do tempo — enquanto a hipótese alternativa (H_1) indica a presença de raiz unitária, caracterizando a não estacionariedade. O KPSS avalia se a variância do componente de tendência estocástica é estatisticamente diferente de zero; se for, rejeita-se a estacionariedade. Conforme Kwiatkowski et al. (1992), a combinação dos testes ADF e KPSS oferece uma estrutura mais robusta para determinar a natureza da série temporal: enquanto o ADF busca evidências contra a estacionariedade, o KPSS busca evidências a favor, permitindo uma interpretação cruzada dos resultados.

2.2.3 Transformação de Séries Temporais

A aplicação de transformações em séries temporais é uma prática amplamente adotada na modelagem estatística, visando melhorar o ajuste e a interpretabilidade dos modelos. Segundo Box e Cox (1964), transformar os dados pode auxiliar na estabilização da variância, na aproximação da normalidade dos erros e na linearização das relações entre variáveis, tornando o modelo mais adequado às suposições clássicas da análise de regressão e previsão. Lütkepohl e Xu (2009) destacam que transformações como a logarítmica podem reduzir a heterocedasticidade e, conseqüentemente, melhorar a precisão das previsões, desde que realmente promovam uma variância mais estável. Como reforçam Hyndman e Athanasopoulos (2021), transformar uma série é, portanto, uma maneira de facilitar seu manejo e potencialmente induzir melhores previsões. A decisão de aplicar ou não uma transformação deve ser avaliada a partir das características da série, algo que será discutido nas seções seguintes.

2.1.3.1 Transformação Box-Cox

A transformação Box–Cox foi desenvolvida como um método estatístico para estabilizar a variância, normalizar os resíduos e linearizar relações entre variáveis em modelos de regressão e séries temporais. Em Box-Cox et al. (*An Analysis of Transformations*, 1964), os autores propõem uma família paramétrica de transformações que dependem de um parâmetro λ , estimado via máxima verossimilhança. Essa abordagem busca encontrar uma transformação dos dados y que satisfaça as suposições clássicas de modelos lineares — normalidade, homocedasticidade e aditividade — quando aplicadas às observações transformadas. A transformação é definida por:

$$y^{(\lambda)} = \begin{cases} \frac{y^\lambda - 1}{\lambda}, & \text{se } \lambda \neq 0 \\ \log(y), & \text{se } \lambda = 0 \end{cases}$$

Equação 13: Transformação Box-Cox

Com esse procedimento, Box e Cox (1964) demonstram que a seleção de λ deve ser feita de modo a maximizar a verossimilhança dos dados transformados, garantindo que o modelo resultante apresente variância constante e distribuição aproximadamente normal. Em termos práticos, quando o valor estimado de λ é próximo de zero, recomenda-se utilizar a transformação. Por outro lado, quando λ próximo de um, entende-se que a série não necessita de transformação, uma vez que a variância já é aproximadamente constante. Essa metodologia é amplamente aplicada na modelagem de séries temporais para tratar heterocedasticidade e assimetria, fornecendo uma base teórica robusta para a aplicação de transformações de potência em análises de previsão.

É importante destacar que a transformação Box-Cox só é válida para observações estritamente positivas, uma vez que envolve operações de potência e logaritmo. Além disso, a interpretação dos resultados deve ser feita na escala transformada, sendo necessário reconverter os valores para a escala original após a previsão, aplicando a transformação inversa. Box e Cox (1964) também enfatizam que o uso da transformação deve equilibrar simplicidade e eficácia estatística, evitando distorções interpretativas excessivas.

2.1.3.2 Transformação Logarítmica

A transformação logarítmica é amplamente utilizada na modelagem de séries temporais como uma forma de estabilizar a variância e reduzir a relação proporcional entre o nível da série e sua dispersão. De acordo com Hyndman e Athanasopoulos (2021), essa técnica é especialmente recomendada quando a amplitude das flutuações aumenta à medida que os valores da série crescem, característica comum em variáveis econômicas e de demanda. Ao aplicar o logaritmo, relações multiplicativas entre as observações tornam-se aditivas, o que facilita o ajuste de modelos lineares e melhora a aderência às suposições de homocedasticidade e normalidade dos resíduos. Lütkepohl e Xu (2009) destacam que o uso do log também pode contribuir para maior precisão preditiva em séries com variância não constante, desde que sua aplicação realmente estabilize a variabilidade dos dados.

Conforme Hyndman e Athanasopoulos (2021), a transformação logarítmica deve ser aplicada apenas a séries estritamente positivas, uma vez que o logaritmo de valores nulos ou negativos é indefinido. Nesses casos, recomenda-se adicionar uma constante a toda a série, de modo a garantir a positividade antes da transformação. A aplicação é realizada ponto a ponto, substituindo cada observação y_t por $\log(y_t)$, o que comprime a escala dos valores maiores e expande a dos menores, reduzindo a amplitude relativa das variações. Após o ajuste do modelo e a obtenção das previsões no domínio transformado, os valores previstos devem ser reconvertidos à escala original por meio da função exponencial inversa, e^{y_t} preservando a interpretabilidade dos resultados.

2.2.4 Realizar previsões com séries temporais

As previsões com séries temporais consistem em estimar valores futuros com base no comportamento histórico de uma variável observada ao longo do tempo. Esse tipo de análise utiliza métodos estatísticos capazes de identificar padrões, tendências e sazonalidades presentes na série, permitindo compreender a estrutura dos dados antes de projetar resultados futuros. De acordo com Hyndman e Athanasopoulos (2021), a etapa de exploração e compreensão dos dados é essencial para garantir previsões confiáveis, uma vez que características como tendência, sazonalidade e aleatoriedade influenciam diretamente na escolha do modelo mais adequado e na precisão dos resultados obtidos.

Dito isso, é importante destacar que existem diversos modelos de séries temporais, cada um com abordagens e estruturas próprias para analisar os dados. Um exemplo simples é o método naïve, que projeta os valores futuros exatamente iguais à última observação disponível, servindo como uma referência básica de desempenho (Hyndman & Athanasopoulos, 2021).

Para compreender se o modelo está reagindo adequadamente à série temporal, é fundamental avaliar a performance das previsões geradas. Para isso, recomenda-se dividir a base de dados em duas etapas: treinamento e teste. A etapa de treinamento é utilizada para estimar os parâmetros dos modelos, enquanto a etapa de teste serve para avaliar a acurácia das previsões em dados não utilizados no ajuste. Essa separação permite verificar o desempenho do modelo em situações reais e reduzir o risco de *overfitting*, do inglês *overfitting*, que ocorre quando o modelo se adapta demais aos dados históricos e perde capacidade preditiva. Como ressaltam os autores, um modelo que se ajusta perfeitamente aos dados de treinamento não necessariamente realiza boas previsões, e o excesso de parâmetros pode ser tão prejudicial quanto a ausência de padrões sistemáticos. Assim, as métricas de acurácia tornam-se ferramentas essenciais para comparar o desempenho entre diferentes modelos e identificar aquele que apresenta o melhor equilíbrio entre ajuste e capacidade de previsão (Hyndman & Athanasopoulos, 2021).

2.2.4.1 Modelos de previsão

No campo da previsão de séries temporais, os modelos podem ser divididos em duas grandes categorias: modelos clássicos e modelos baseados em aprendizado de máquina. Os modelos clássicos, amplamente abordados por Hyndman e Athanasopoulos (2021), como os métodos de suavização exponencial (ETS) e os modelos ARIMA, baseiam-se em fundamentos estatísticos que descrevem relações temporais explícitas nos dados, utilizando parâmetros definidos a partir de propriedades como tendência e sazonalidade. Já os modelos de aprendizado de máquina, como Random Forest e redes neurais recorrentes, buscam capturar padrões complexos de forma não linear, aprendendo diretamente com os dados sem pressupor uma estrutura estatística específica. Dessa forma, enquanto os modelos clássicos oferecem maior interpretabilidade e simplicidade, os métodos de machine learning tendem a apresentar melhor desempenho em séries com comportamentos mais irregulares ou com múltiplas variáveis explicativas.

2.2.4.1.1 Modelos Clássicos

2.2.4.1.1.1 Suavização exponencial (ETS)

O modelo ETS (Error, Trend, Seasonal) é um método clássico de previsão baseado na suavização exponencial, em que as observações mais recentes recebem maior peso na estimativa dos valores futuros, enquanto as mais antigas têm influência decrescente. Esse modelo busca capturar três componentes fundamentais de uma série temporal — erro, tendência e sazonalidade — combinando-os de forma aditiva ou multiplicativa conforme o comportamento dos dados. Dessa maneira, o ETS é capaz de se ajustar a diferentes padrões, como séries com tendência linear, tendência amortecida ou sazonalidade regular. Uma das principais vantagens desse método é sua flexibilidade e simplicidade, permitindo gerar previsões rápidas e robustas sem exigir transformações adicionais ou pressupostos complexos de estacionariedade (Hyndman & Athanasopoulos, 2021).

2.2.4.1.1.2 SARIMA

Os modelos SARIMA (Seasonal Autoregressive Integrated Moving Average) representam uma abordagem alternativa à previsão de séries temporais, distinta da lógica do modelo ETS. Enquanto o ETS foca em decompor a série em seus componentes estruturais — tendência, sazonalidade e erro — o SARIMA busca capturar as relações de dependência temporal existentes entre as observações por meio da autocorrelação. Em outras palavras, esse modelo parte do princípio de que os valores futuros podem ser explicados pelos comportamentos passados da própria série, considerando tanto padrões de curto prazo quanto efeitos sazonais recorrentes. Essa capacidade de modelar a interdependência entre os dados torna o SARIMA especialmente adequado para séries que apresentam padrões repetitivos e correlação significativa entre períodos consecutivos.

Para que o modelo SARIMA seja aplicado de forma adequada, é fundamental que a série temporal seja estacionária, ou seja, que apresente média e variância aproximadamente constantes ao longo do tempo. A estacionariedade garante que as relações de dependência observadas entre os períodos sejam estáveis permitindo que o modelo capture corretamente a estrutura de autocorrelação. No entanto, muitas séries reais apresentam tendência ou sazonalidade, o que viola essa condição. Para contornar esse problema, realiza-se o processo de diferenciação, que consiste em subtrair o valor atual pelo valor anterior, removendo variações

sistemáticas e estabilizando a série em torno de uma média. Essa diferenciação pode ser feita uma ou mais vezes, originando as chamadas primeira e segunda diferença, de acordo com o grau necessário para tornar a série estacionária (Hyndman & Athanasopoulos, 2021).

O modelo SARIMA(p, d, q)(P, D, Q)_s combina componentes autorregressivos (AR), de médias móveis (MA) e de diferenciação, tanto em sua forma regular quanto sazonal. Os parâmetros p, d e q representam, respectivamente, a ordem autorregressiva, o número de diferenças não sazonais e a ordem da média móvel. Já os parâmetros P, D e Q correspondem às mesmas características, porém aplicadas à componente sazonal da série, enquanto “s” indica o período da sazonalidade (por exemplo, 12 para dados mensais). A combinação dessas partes torna o SARIMA um dos modelos mais robustos e amplamente utilizados na previsão de séries temporais, especialmente quando os dados apresentam comportamento periódico e dependência temporal significativa (Hyndman & Athanasopoulos, 2021).

2.2.4.1.2 Modelos de Machine Learning

2.2.4.1.2.1 Croston

O modelo Croston, proposto por Croston (1972), é amplamente utilizado para a previsão de demandas intermitentes, caracterizadas por longos períodos de ausência de demanda intercalados com valores positivos irregulares. Nessas situações, métodos tradicionais, como a suavização exponencial simples, tendem a gerar previsões imprecisas, pois não conseguem lidar adequadamente com os períodos de zero demanda (Bertolde & Xavier Jr., 2013). O método de Croston resolve esse problema ao decompor a série em dois componentes: o tamanho médio da demanda não nula (Z_t) e o intervalo médio entre ocorrências (P_t). Ambas as variáveis são atualizadas por meio de suavização exponencial, conforme as equações:

$$\hat{Z}_t = \alpha Z_t + (1 - \alpha)\hat{Z}_{t-1}$$

$$\hat{P}_t = \alpha P_t + (1 - \alpha)\hat{P}_{t-1}$$

$$\hat{D}_t = \frac{\hat{Z}_t}{\hat{P}_t}$$

Equação 14: Equações do Modelo Croston

Em que α é o parâmetro de suavização, Z_t representa o tamanho da demanda quando ocorre uma venda, e P_t é o intervalo entre duas demandas consecutivas. Assim, o valor previsto \hat{D}_t representa a taxa média de demanda por período. De acordo com Kaya, Sahin e Demirel (2020), esse modelo e suas variações — como as de Syntetos-Boylan, Leven-Segerstedt e Vinh — apresentam bom desempenho em contextos de baixa frequência de consumo e alta variabilidade, sendo amplamente aplicados em previsões de itens de reposição e manutenção. (Croston, 1972; Bertolde & Xavier Jr., 2013; Kaya, Sahin & Demirel, 2020)

O modelo SBA (*Syntetos-Boylan Approximation*) foi desenvolvido por Syntetos e Boylan (2001) como uma extensão do método de Croston, com o objetivo de corrigir o viés presente em suas estimativas. Estudos mostraram que o modelo original de Croston tende a superestimar a demanda, o que pode levar a níveis de estoque excessivos (Bertolde & Xavier Jr., 2013). Para reduzir esse problema, Syntetos e Boylan (2001) propuseram um fator de correção aplicado à fórmula original, ajustando a previsão pela expressão:

$$\hat{D}_t = (1 - \frac{\alpha}{2}) \frac{\hat{Z}_t}{\hat{P}_t}$$

Equação 15: Expressão do SBA

De acordo com Kaya, Sahin e Demirel (2020), essa modificação reduz o viés e melhora a precisão das previsões em séries intermitentes, especialmente naquelas classificadas como *intermittent* e *lumpy*, segundo a categorização baseada no ADI e no CV². Assim, o SBA tornou-se uma das variantes mais utilizadas do método de Croston, equilibrando simplicidade e maior acurácia em contextos de demanda irregular.

O modelo TSB (*Teunter-Syntetos-Babai*) foi proposto como uma nova extensão do método de Croston, com o objetivo de aprimorar a modelagem da probabilidade de ocorrência da demanda ao longo do tempo. Diferentemente dos modelos Croston e SBA, que pressupõem uma taxa de demanda constante entre as ocorrências, o TSB introduz uma estrutura que atualiza não apenas o tamanho médio da demanda, mas também a probabilidade de uma nova demanda ocorrer em cada período (Teunter, Syntetos & Babai, 2011). Dessa forma, o método é capaz de reagir mais rapidamente a mudanças na frequência de demanda, tornando-se especialmente útil para séries intermitentes com períodos de inatividade prolongados. Matematicamente, o modelo é definido pelas seguintes equações:

$$\hat{Z}_t = \alpha Z_t + (1 - \alpha)\hat{Z}_{t-1}$$

$$\hat{P}_t = \beta P_t + (1 - \beta)\hat{P}_{t-1}$$

$$\hat{D}_t = \hat{P}_t \times \hat{Z}_t$$

Equação 16: Equações do TSB

O TSB apresenta melhor desempenho em séries de demanda altamente irregulares, pois é capaz de reduzir o viés presente nas estimativas e ajustar-se a mudanças estruturais na frequência de ocorrência dos pedidos, superando os resultados dos modelos Croston e SBA em diversos contextos práticos (Teunter, Syntetos & Babai, 2011; Kaya, Sahin & Demirel, 2020).

2.2.4.1.2.2 Random Forest

O modelo Random Forest (RF), proposto por Breiman (2001), é um algoritmo de aprendizado de máquina baseado em árvores de decisão que pode ser aplicado tanto em problemas de classificação quanto de regressão. Sua principal característica é o uso do método *ensemble*, combinando diversas árvores geradas a partir de subconjuntos aleatórios dos dados e dos preditores — processo conhecido como *bagging* — para reduzir a variância e melhorar a precisão das previsões. O RF é especialmente útil para lidar com dados complexos e não lineares, sendo capaz de modelar relações intrincadas entre variáveis e identificar automaticamente os preditores mais relevantes. No contexto de séries temporais, o RF utiliza valores defasados da própria série como variáveis explicativas, permitindo capturar padrões de dependência temporal sem a necessidade de pressupor estacionariedade ou linearidade. Além disso, o Random Forest apresenta bom desempenho preditivo, mesmo em séries sazonais e não estacionárias, tornando-se uma alternativa robusta aos modelos clássicos como ARIMA e ETS (Breiman, 2001; Tyralis & Papacharalampous, 2017; Teixeira & Rodrigues, 2022).

A aplicação do Random Forest em séries temporais segue uma lógica semelhante à de regressões tradicionais, em que o algoritmo aprende a relação entre a variável de interesse e seus valores passados. Conforme proposto por Tyralis e Papacharalampous (2017), o modelo é treinado a partir de um conjunto de observações x_t , utilizando variáveis defasadas como preditores. Assim, a previsão de um novo valor é obtida por meio de uma função $g(\cdot)$ ajustada pelo algoritmo, expressa como:

$$x_t = g(x_{t-1}, x_{t-2}, \dots, x_{t-k})$$

Equação 17: Algoritmo do Random Forest

em que k representa o número de defasagens consideradas. Cada árvore da floresta é construída a partir de subconjuntos aleatórios das observações e variáveis, e o resultado final é calculado pela média das previsões individuais das árvores, reduzindo o risco de *overfitting*. O desempenho do modelo depende diretamente da quantidade de defasagens escolhidas: poucas defasagens podem limitar a informação temporal disponível, enquanto um número excessivo reduz o tamanho do conjunto de treinamento e pode prejudicar a acurácia. Dessa forma, o Random Forest se mostra eficaz para previsões de curto prazo, capturando padrões recentes da série sem necessidade de suposições estatísticas rígidas (Tyralis & Papacharalampous, 2017).

2.2.4.1.2.3 LSTM

O modelo *Long Short-Term Memory* (LSTM) é uma variação das redes neurais recorrentes (RNN) desenvolvida para aprimorar a capacidade dessas redes em capturar dependências de longo prazo em séries temporais. Enquanto as RNNs tradicionais sofrem com o problema do *vanishing gradient*, que dificulta o aprendizado de padrões distantes no tempo, o LSTM introduz um mecanismo de memória interna composto por células e portas de entrada, esquecimento e saída, que controlam o fluxo e a retenção das informações relevantes ao longo da sequência (Shi et al., 2015). Essa estrutura permite que o modelo mantenha e atualize informações de forma seletiva, preservando relações temporais mais complexas e melhorando o desempenho preditivo. Segundo Fischer e Krauss (2018), as redes LSTM demonstram desempenho superior aos modelos tradicionais de previsão, principalmente em séries não lineares, sazonais e de alta variabilidade, sendo amplamente aplicadas em contextos financeiros, meteorológicos e de previsão de demanda.

Matematicamente, a rede LSTM é composta por unidades chamadas células de memória, responsáveis por armazenar e atualizar informações relevantes ao longo do tempo. Cada célula contém três portas principais: porta de esquecimento (f_t), porta de entrada (i_t) e porta de saída (o_t) que determinam, respectivamente, quais informações devem ser descartadas, atualizadas e transmitidas à saída. O estado interno da célula (c_t) é atualizado com base nas seguintes equações:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

$$i_t \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t \odot \tanh(c_t)$$

Equação 18: Equações do LSTM

em que x_t representa a entrada no tempo t , h_t é a saída oculta, σ é a função sigmoide e \odot denota a multiplicação elemento a elemento. As matrizes W e os vetores b correspondem aos pesos e vieses aprendidos durante o treinamento. Esse conjunto de operações permite ao modelo armazenar informações relevantes de longo prazo e evitar a perda de gradientes, o que o torna altamente eficaz em previsões de séries temporais com forte dependência sequencial (Shi et al., 2015; Fischer & Krauss, 2018).

2.2.3.2 Métricas de Acurácia

A avaliação do desempenho dos modelos de previsão é uma etapa essencial para garantir a confiabilidade dos resultados obtidos. As métricas de acurácia permitem quantificar o erro entre os valores observados e os valores previstos, servindo como base para a comparação entre diferentes métodos de modelagem. De acordo com Hyndman e Athanasopoulos (2021), um erro de previsão representa a diferença entre o valor real e o valor estimado pelo modelo, expressando a parcela imprevisível da série temporal. Em termos matemáticos, o erro pode ser representado como $e_{T+h} = y_{T+h} - \hat{y}_{T+h|T}$, em que y_{T+h} é o valor observado e $\hat{y}_{T+h|T}$ é o valor previsto com base nos dados até o tempo. Dessa forma, a análise dos erros de previsão permite compreender o quanto as estimativas do modelo se afastam dos valores reais, fornecendo uma medida objetiva de sua precisão.

2.2.3.2.1 MAE e RMSE

Dentre as principais métricas de avaliação, destacam-se o Erro Absoluto Médio (MAE) e a Raiz do Erro Quadrático Médio (RMSE). O MAE representa a média dos valores absolutos das diferenças entre as previsões e os valores observados, indicando o erro médio cometido pelo modelo sem considerar o sentido da diferença. Sua fórmula é dada por:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

Equação 19: Fórmula do MAE

Esse indicador é simples e intuitivo, sendo amplamente utilizado por expressar o erro médio em unidades da própria variável analisada. Já o RMSE é uma métrica semelhante, porém eleva as diferenças ao quadrado antes de calcular a média e, em seguida, aplica a raiz quadrada, conforme a expressão:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

Equação 20: Fórmula do RMSE

Essa característica faz com que o RMSE atribua maior peso aos erros grandes, sendo mais sensível a desvios extremos. Enquanto o MAE fornece uma visão geral da magnitude dos erros, o RMSE é mais apropriado quando se deseja enfatizar a ocorrência de previsões muito distantes dos valores reais. (Hyndman & Athanasopoulos, 2021)

2.2.3.2.2 MAPE e sMAPE

Além das métricas baseadas em erros absolutos, também podem ser utilizadas medidas percentuais, que possuem a vantagem de serem livres de unidades e permitem comparar o desempenho da previsão entre diferentes séries. A mais comum é o Erro Percentual Absoluto Médio (MAPE), definido como:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

Equação 21: Fórmula do MAPE

O MAPE expressa o erro médio em termos percentuais, oferecendo uma interpretação direta da acurácia do modelo. No entanto, Hyndman e Athanasopoulos (2021) destacam que essa métrica pode se tornar indefinida quando $y_t = 0$ e tende a apresentar valores extremos quando y_t está próximo de zero. Como alternativa, os autores apresentam o Erro Percentual Absoluto Médio Simétrico (sMAPE), definido por:

$$sMAPE = \frac{100}{n} \sum_{t=1}^n \frac{2 \times |y_t - \hat{y}_t|}{|y_t| + |\hat{y}_t|}$$

Equação 22: Fórmula do sMAPE

Essa forma busca reduzir o impacto de valores muito baixos de y_t , tornando a comparação entre modelos mais equilibrada. Entretanto, mesmo o sMAPE pode se tornar instável em séries com valores próximos de zero, devendo ser utilizado com cautela. (Hyndman & Athanasopoulos, 2021)

2.3 Planejamento da Produção: Impactos em Custos e Estoque

2.3.1 MPS

O Planejamento Mestre da Produção, do inglês *Master Production Schedule* (MPS) é uma ferramenta fundamental do Planejamento e Controle da Produção (PCP), responsável por transformar o plano agregado de produção em uma visualização que permite definir o que será produzido, em que quantidade e em qual período. O MPS atua como elo entre o planejamento estratégico e a execução operacional, garantindo o equilíbrio entre a demanda do mercado e a capacidade produtiva disponível (Slack et al 2009).

O objetivo principal do MPS é traduzir as metas de produção em ordens realizáveis, assegurando o uso eficiente dos recursos e o atendimento aos prazos de entrega. Para isso, o

planejamento mestre detalha a produção de itens finais considerando prazos de fornecimento, restrições de capacidade e políticas de estoque (Tubino, 2009).

Além de sua função técnica, o MPS também desempenha um papel estratégico, pois auxilia na tomada de decisões relacionadas à priorização de pedidos, à gestão de capacidade e à análise de cenários de demanda. Ao integrar informações de vendas, estoques e capacidade de produção, o MPS contribui para o aumento da confiabilidade nos prazos de entrega e para a redução de custos operacionais. (Slack et al., 2009).

2.3.1.1 Estrutura e Funcionamento do MPS

O Programa Mestre da Produção (MPS) materializa-se em um registro estruturado que organiza, por período, às previsões de demanda, pedidos firmes, estoque, ordens planejadas e disponibilidade para prometer (Slack, 2009). No cabeçalho do registro, constam o item planejado, o tamanho de lote, o lead time, o estoque inicial “em mãos” e o horizonte temporal (semanas/meses), informações indispensáveis para a coerência entre demanda e capacidade (Tubino, 2009).

Item: XXX Lote: YY Unid Lead Time: ZZ (tempo)								
Período (Ex: semanas)	Mês 1				Mês 2			
Em mão: XX	1	2	3	4	1	2	3	4
Previsto								
Em Carteira								
Estoque Projetado								
Qtde. MPS								
Início MPS								
ATP								
ATP (acum.)								

Figura 2: Modelo de Registro MPS

Fonte: Os autores (2025)

O estoque projetado é calculado como um saldo recursivo que agrega o estoque do período anterior, adiciona o que será recebido via MPS e subtrai a demanda relevante do período, assegurando visibilidade antecipada de faltas e sobras (Jacobs et al., 2018). A relação operacional pode ser escrita por período t :

$$\text{Estoque Projetado}_t = \text{Estoque}_{t-1} + \text{Qtde. MPS}_t - \max \{ \text{Previsto}_t, \text{Em Carteira}_t \}$$

Equação 23: Cálculo do Estoque Projetado por Período

O campo Início MPS desloca a liberação das ordens para $t - \text{lead time}$, garantindo disponibilidade na data planejada de recebimento e sincronizando o MPS com tempos de

suprimento e fabricação (Krajewski, 2017). Essa defasagem é central para alinhar calendários de produção e abastecimento, reduzindo atrasos e retrabalhos derivados de disparos tardios (Tubino, 2009).

O *Available to Promise* (ATP) representa a parte não comprometida do plano, isto é, o que pode ser prometido a novos pedidos sem alterar o MPS aprovado, sendo chave para a integração vendas-produção (Jacobs et al., 2018). Para um período com recebimento de lote do MPS, o ATP é usualmente calculado da seguinte forma:

$$ATP_t = Qtde.MPS_t - \sum_{\tau=t}^{(próx.MPS)-1} Pedidos Firmes_{\tau}$$

Equação 24: Cálculo do ATP por Período

A apresentação do ATP acumulado facilita a leitura comercial de “quanto ainda posso prometer” ao longo do horizonte, apoiando decisões de priorização e datas de entrega com menor necessidade de replanejamento (Slack, 2009).

2.3.2 Custos

O planejamento e controle da produção deve equilibrar três componentes fundamentais de custo: custo de preparação, do inglês *setup* e o custo de manutenção de estoque, que, somados, compõem o custo relevante total do sistema de produção (Tubino, 2009; Corrêa, 2008). Esses custos representam as consequências econômicas das decisões de tamanho de lote e de nível de estoque e, portanto, orientam o ponto de equilíbrio entre eficiência produtiva e nível de serviço ao cliente (Krajewski, 2017).

O custo de *setup* corresponde ao dispêndio associado à preparação de um lote de produção, englobando atividades como ajustes de máquina, limpeza, calibração, emissão de ordens e movimentações iniciais. Esse custo é representado pelo parâmetro *A* e tende a diminuir à medida que se aumentam os tamanhos dos lotes, pois menos *setups* são necessários dentro de um mesmo horizonte de tempo (Tubino, 2009). O custo de *setup* pode ser definido como:

$$C_{setup} = \frac{A \times D}{Q}$$

Equação 25: Cálculo do Custo de Preparação (Setup)

O custo de manutenção de estoque (ou custo de manter) está associado ao capital empatado, ao espaço físico, às perdas por deterioração e ao custo de oportunidade. Esse custo é proporcional ao nível médio de estoque e é representado por H (custo unitário de manter um item por período). O custo de manutenção de estoque pode ser expresso da seguinte forma:

$$C_{manter} = \frac{H \times Q}{2}$$

Equação 26: Cálculo do Custo de Manter o Estoque

A soma desses dois componentes resulta no custo relevante total (CRT), que representa o custo operacional associado a uma determinada política de lote (Tubino, 2009). O modelo clássico de lote econômico de compra define o CRT por:

$$CRT(Q) = \frac{A \times D}{Q} + \frac{H \times Q}{2}$$

Equação 27: Cálculo do Custo Relevante Total no Modelo EOQ

Em sistemas produtivos, quando a taxa de produção (p) é finita e maior que a demanda D , o modelo do lote econômico de produção ajusta o custo de manutenção para refletir o estoque médio efetivo, resultando em:

$$CRT(Q) = \frac{A \times D}{Q} + H \times \left(1 - \frac{D}{P}\right) \times \frac{Q}{2}$$

Equação 28: Cálculo do Custo Relevante Total no Modelo EPQ

2.3.3 Estoque de Segurança

O estoque de segurança é a reserva adicional de produtos mantida para proteger o sistema produtivo contra incertezas na demanda e no tempo de reposição. Seu objetivo é minimizar o risco de ruptura sem gerar excessos de capital imobilizado, garantindo o nível de serviço desejado (Slack, 2009).

Nos modelos clássicos, o estoque de segurança é calculado a partir da variabilidade da demanda e do nível de serviço estabelecido, sendo determinado pela expressão geral:

$$SS = z \times \sigma_D \times \sqrt{L}$$

Equação 29: Cálculo Clássico do Estoque de Segurança

Em que z é o fator associado ao nível de serviço (obtido da distribuição normal padrão), σ_D é o desvio padrão da demanda e L é o *lead time* (Tubino, 2009). Esse formato é adequado quando a incerteza é relativamente estável em termos absolutos, independentemente da magnitude da demanda (Tubino, 2009).

Entretanto, ainda é possível calcular o estoque de segurança utilizando o Método do Coeficiente de Variação (CV), onde o desvio padrão (σ_D) é estimado como uma função da demanda prevista ($\sigma_t = CV \times D_t$), tornando o estoque de segurança sensível a oscilações da demanda mensal (OLSEN, 2015). Nesse caso, o estoque de segurança do período t é calculado como:

$$SS = z \times (CV \times D_t) \times \sqrt{L}$$

Equação 30: Cálculo do Estoque de Segurança Utilizando o Coeficiente de Variação

3 METODOLOGIA

Este capítulo está estruturado em 07 seções. Na **Seção 3.1**, apresenta-se a metodologia adotada para condução do estudo de forma mais generalizada, justificando sua escolha e ressaltando sua adequação ao tema e aos resultados almejados. A **Seção 3.2** aborda de forma mais detalhada quais são exatamente os métodos combinados dentro da metodologia *Design Science Research* (DSR). Na **Seção 3.3**, é realizada a definição do problema a ser abordado no caso, como contexto para o problema geral e os específicos bem como a explicitação de como eles serão alcançados. A **Seção 3.4** aprofunda-se na revisão da literatura utilizada para elaboração do artefato, bem como toda estrutura e base para desenvolvimento do artefato. A **Seção 3.5** detalha o processo de desenvolvimento do artefato proposto, os módulos inclusos, além de definir o fluxo durante utilização. A **Seção 3.6** atua em trazer o perfil dos práticos que farão a avaliação empírica e analítica do artefato. Por fim, a **Seção 3.7** apresenta o plano de disseminação da ferramenta para uso dentro do caso estudado.

3.1 *Design Science Research* (DSR)

Este trabalho adota como método de pesquisa a DSR, amplamente utilizada na Engenharia de Produção para a concepção de artefatos que solucionam problemas reais de natureza organizacional. A escolha do DSR se justifica pela natureza prática e aplicada do estudo, cujo objetivo central não é apenas descrever ou analisar um fenômeno existente, mas desenvolver um artefato que integre previsões de demanda às ferramentas de PCP. Como destacam Lacerda et al. (2013), a DSR diferencia-se de métodos tradicionais, justamente por ter como propósito principal a construção e avaliação de artefatos que atendam a classes de problemas relevantes na área.

No contexto do presente estudo, o artefato a ser desenvolvido corresponde a uma interface para apoio à decisão no fluxo de gestão de estoques. O artefato desenvolvido no presente trabalho será validado a partir do teste usando dados históricos reais de demanda (2017 a 2025) extraídos do sistema *TOTVS* da empresa, bem como avaliação dos práticos da área.

A adoção do DSR é particularmente relevante neste trabalho, pois a pesquisa se insere em uma classe de problemas voltada ao planejamento e controle da produção, onde há necessidade de ferramentas que combinem rigor científico e aplicabilidade prática. O método possibilita estruturar o processo de forma sistemática, abrangendo desde a identificação do problema, o desenvolvimento do artefato e a sua avaliação, até a comunicação dos resultados à

Companhia. Dessa forma, garante-se que o conhecimento produzido seja cientificamente válido e, ao mesmo tempo, útil para apoiar as decisões organizacionais (Lacerda et al., 2013).

3.2 Estrutura do DSR

A DSR é uma abordagem multimétodo que integra técnicas qualitativas, quantitativas, projetuais e computacionais para apoiar a construção e avaliação de artefatos voltados à solução de problemas organizacionais. Segundo Lacerda et al. (2013), esse caráter híbrido permite unir rigor científico — por meio de fundamentos teóricos e métodos analíticos — e relevância prática, ao aplicar a solução em um contexto real.

No presente estudo, diferentes métodos foram articulados conforme as necessidades do ciclo de design: métodos qualitativos para compreender o processo produtivo e o contexto da empresa; métodos quantitativos e computacionais para modelar dados históricos, gerar previsões e implementar o artefato; e métodos projetuais para estruturar o fluxo lógico da solução. A aplicação em estudo de caso garantiu a validação empírica da proposta.

3.3 Conscientização do Problema

A etapa de Conscientização do Problema consiste em compreender de forma estruturada o contexto organizacional no qual o artefato será aplicado, conforme preconiza a DSR. Nesta seção, descreve-se o processo metodológico utilizado para identificar e delimitar o problema que motivou o desenvolvimento da solução proposta. Para isso, recorreu-se inicialmente a técnicas qualitativas, como visitas técnicas, entrevistas exploratórias e observações diretas dos processos, complementadas por análises preliminares dos dados disponíveis. Além disso, uma revisão de literatura foi conduzida para situar o problema em relação aos desafios amplamente discutidos no âmbito do Planejamento e Controle da Produção (PCP) e da previsão de demanda. A combinação dessas abordagens permitiu estruturar o problema geral e os problemas específicos que orientam as etapas subsequentes deste estudo.

3.3.1 Introdução: como o problema foi definido

A etapa de Conscientização do Problema corresponde ao ponto de partida da DSR e tem como objetivo entender, de forma abrangente, a situação que motiva o desenvolvimento do artefato. Nessa fase inicial, o pesquisador deve buscar compreender a natureza do problema, seus impactos e as condições do ambiente no qual a solução será aplicada. A literatura destaca que essa compreensão pode emergir tanto da análise teórica quanto de evidências empíricas

obtidas no campo, permitindo identificar necessidades, limitações e oportunidades que justifiquem a elaboração de um artefato. Embora a DSR não prescreva um procedimento único para realizar essa aproximação inicial, a etapa de conscientização é fundamental para garantir que o problema seja adequadamente definido e que a solução proposta esteja alinhada às demandas reais do contexto estudado (Lacerda et al., 2013).

Em consonância com essa orientação metodológica, este estudo adotou uma abordagem qualitativa inicial para a compreensão do problema. Foram realizadas visitas ao campo, entrevistas exploratórias com profissionais envolvidos no processo produtivo, análises documentais e uma avaliação preliminar dos dados históricos disponíveis. Esses procedimentos, utilizados de forma complementar, possibilitaram captar diferentes perspectivas sobre o funcionamento das atividades, identificar potenciais limitações dos métodos atualmente empregados e compreender como o problema se manifesta na prática.

3.3.2 Entendendo os prejuízos da problemática nas Empresas

Compreender como a previsão de demanda e o PCP afetam o desempenho das empresas é fundamental para contextualizar o problema deste estudo. Falhas de previsão — como estimativas imprecisas, métodos inadequados ou falta de rigor estatístico — impactam estoques, custos, capacidade produtiva e nível de serviço, sendo apontadas como uma das principais fontes de ineficiência industrial (Machines et al., 2024). Além disso, a dificuldade de integrar previsão, plano-mestre e necessidades de materiais compromete a consistência das decisões produtivas.

A baixa qualidade das previsões de demanda muitas vezes decorre da dependência de julgamentos subjetivos, substituindo métodos quantitativos estruturados. Conforme *Machines et al.* (2024), muitas empresas ainda baseiam decisões em intuição, suposições e percepções individuais, aumentando a incerteza e reduzindo a confiabilidade do planejamento. Sem análises estatísticas adequadas, padrões como tendência e sazonalidade deixam de ser identificados, fazendo com que oscilações naturais sejam interpretadas como simples ruído. Como resultado, oportunidades de modelagem são perdidas, e o processo de previsão se torna menos preciso e menos eficaz para apoiar o PCP.

Além disso, estimativas mal configuradas geram divergências entre o previsto e o realizado, criando desbalanceamentos que levam tanto ao excesso quanto à falta de produção, ou seja, uma instabilidade operacional. Esses desvios resultam em estoques elevados — com

aumento de custos e capital imobilizado — ou em rupturas e atrasos no atendimento. Ambos os cenários reduzem o nível de serviço e exigem ações corretivas, como *setups* adicionais, compras emergenciais ou ajustes de última hora, elevando os custos associados à baixa qualidade das previsões. geram custos adicionais associados à baixa qualidade das previsões (Machines et al., 2024).

Diante desses problemas — que incluem previsões imprecisas, decisões empíricas e falta de integração com o PCP — torna-se necessário identificar, na literatura, alternativas que possam mitigar essas ineficiências. Assim, surge a seguinte questão norteadora da revisão teórica: quais soluções a literatura propõe para aprimorar a previsão de demanda e sua integração ao Planejamento e Controle da Produção, reduzindo ineficiências e melhorando o desempenho operacional em ambientes de manufatura?

3.4 Sugestão de Soluções

Com base no problema identificado e guiados pela questão de revisão de literatura — que busca compreender quais soluções são propostas para aprimorar a previsão de demanda e sua integração ao PCP — esta seção apresenta as abordagens metodológicas consideradas para a construção do artefato. Inicialmente, são discutidas as técnicas destacadas pela literatura como adequadas para enfrentar os desafios de previsão e planejamento. Em seguida, descreve-se a estrutura metodológica adotada, organizada em etapas de pré-processamento, processamento e pós-processamento. Por fim, detalha-se o processo de seleção da abordagem utilizada no estudo, estabelecendo os fundamentos que orientam o desenvolvimento do artefato apresentado no capítulo seguinte.

Combinação de palavras-chaves com expressões booleanas “OR” e “AND”

```
( "Artificial Intelligence" OR "Machine Learning" OR "Deep Learning" ) AND ( "Inventory Management" OR "Stock Control" OR "Warehouse Management" OR "Inventory Optimization" ) AND ( "Demand Forecasting" OR "Sales Forecasting" OR "Demand Prediction" ) AND ( "Manufacturing Industry" OR "Furniture Industry" OR "Woodworking Industry" OR "School Furniture" OR "Industrial Production" OR "Production Planning" ) AND ("Make-to-Order") AND ( LIMIT-TO ( DOCTYPE,"ar" ) OR LIMIT-TO ( DOCTYPE,"cp" ) ) AND ( LIMIT-TO ( SUBJAREA,"ENGI" ) OR LIMIT-TO (
```

SUBJAREA,"BUSI")) AND (LIMIT-TO (LANGUAGE,"English") OR LIMIT-TO (LANGUAGE,"Portuguese"))

Tabela 1: Pesquisas e Strings de Busca

Fonte: Os autores (2025)

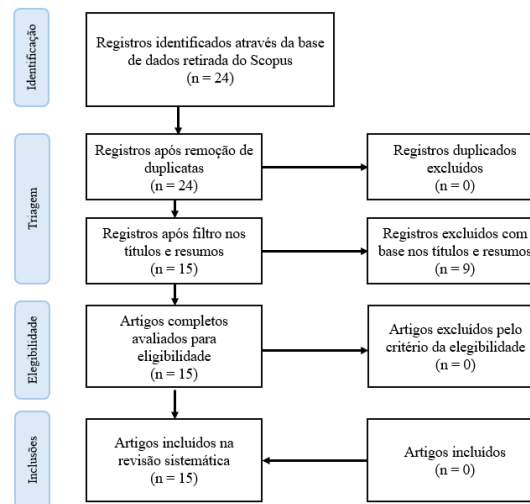


Figura 4: Diagrama Prisma

Fonte: Os autores (2025)

Além disso, ao longo do desenvolvimento deste estudo, foram consultadas diversas fontes pertencentes à chamada literatura cinzenta, composta tanto por obras clássicas quanto por estudos recentes que fundamentam a discussão teórica e metodológica. No total, foram utilizados 13 livros que abrangem temas centrais como Planejamento e Controle da Produção, gestão de estoques, previsão de demanda e análise estatística, fornecendo a base conceitual necessária para estruturar o artefato proposto. Complementarmente, foram analisados 30 artigos científicos, incluindo revisões sistemáticas, estudos aplicados e contribuições de referência em séries temporais, aprendizagem de máquina, heterocedasticidade e métodos econométricos. Esse conjunto diversificado de fontes permite alinhar o trabalho às práticas consolidadas da área, ao mesmo tempo em que incorpora avanços recentes da literatura, fortalecendo o rigor teórico e a atualidade da solução apresentada.

O fluxo analítico de dados normalmente envolve três etapas fundamentais — pré-processamento, processamento e pós-processamento — que estruturam a construção de modelos e análises confiáveis. O pré-processamento consiste na preparação da base, englobando limpeza, transformação, seleção e redução dos dados, com o objetivo de eliminar

ruídos, inconsistências e redundâncias. Essa etapa é considerada crítica porque, como destacam Ramírez-Gallego et al. (2017), a qualidade do pré-processamento determina diretamente o desempenho e a estabilidade dos modelos aplicados posteriormente, além de evitar que padrões espúrios comprometam a eficiência dos algoritmos. O processamento corresponde à aplicação das técnicas analíticas ou preditivas escolhidas, enquanto o pós-processamento envolve a interpretação dos resultados, a avaliação da performance e a verificação de sua utilidade prática, garantindo que as decisões finais se baseiem em evidências consistentes e alinhadas ao contexto estudado.

À luz desse fluxo metodológico e considerando a necessidade de validar empiricamente o artefato proposto, emerge a pergunta do estudo de caso: como aplicar e avaliar, em uma empresa moveleira, um artefato que integra previsões de demanda às ferramentas de PCP, analisando seus impactos na operação e na tomada de decisão?

3.4.1 Pré-Processamento

No processo de pré-processamento, a base de dados foi inicialmente estruturada por meio do algoritmo de clusterização *K-means* na plataforma *Microsoft Excel*, técnica amplamente empregada para agrupar elementos com características semelhantes em conjuntos homogêneos. Para a aplicação do método, utilizou-se a quantidade de demanda como atributo de agrupamento e a distância euclidiana como métrica de similaridade, permitindo que os produtos fossem distribuídos em grupos de forma a minimizar a variabilidade interna em relação aos centróides, que representam o volume médio de cada cluster. Dessa forma, a clusterização possibilitou segmentar os itens em três categorias — alto, médio e baixo volume — organizando a base de maneira consistente antes da modelagem quantitativa (Beltrame; Fonseca, 2010).

Além disso, sobre o grupo de alto volume, aplicou-se a classificação ABC, metodologia fundamentada no Princípio de Pareto que classifica itens conforme sua relevância econômica e operacional. Essa combinação de segmentação e priorização possibilitou identificar o *Stock Keeping Unit* (SKU) mais representativo do portfólio, direcionando a análise para os produtos de maior impacto (Dias, 2015).

Após a identificação do SKU mais representativo, procedeu-se à avaliação estatística da série temporal correspondente, etapa essencial para fundamentar a escolha dos métodos de previsão mais adequados. Inicialmente, foram aplicadas métricas específicas para análise de

intermitência, tais como o ADI e o CV^2 , conforme proposto por Kaya, Sahin e Demirel (2020). Essas medidas permitiram caracterizar a frequência de ocorrência das demandas e a variabilidade dos tamanhos das demandas não nulas, fornecendo uma visão preliminar do padrão de comportamento da série. Essa etapa antecede a seleção dos modelos preditivos porque orienta decisões sobre a necessidade de métodos voltados a séries intermitentes ou técnicas tradicionais para séries mais regulares.

Além disso, foram conduzidos testes estatísticos para examinar propriedades estruturais da série temporal, garantindo compatibilidade entre suas características e os modelos que seriam posteriormente empregados. Para investigar heterocedasticidade, utilizaram-se o teste de Breusch–Pagan (Greene, 2018) e o modelo ARCH de Engle (1982), enquanto a normalidade foi avaliada por meio do teste de Shapiro–Wilk (Shapiro; Wilk, 1965) e complementada pelo coeficiente de assimetria (Costa Neto, 2002). A estacionariedade da série foi analisada com os testes ADF (Dickey; Fuller, 1979) e KPSS (Kwiatkowski et al., 1992), cuja combinação fornece um diagnóstico robusto sobre a presença de tendência estocástica ou raiz unitária. A aplicação conjunta desses procedimentos permitiu construir uma caracterização estatística sólida da série, oferecendo subsídios essenciais para a definição dos modelos de previsão utilizados no processamento.

Por fim, avaliou-se também a intensidade dos componentes estruturais da série — tendência e sazonalidade — a fim de compreender seu grau de explicação e orientar a modelagem de forma mais precisa. Para isso, realizou-se a decomposição STL e mensurou-se a força da tendência (F_t) e a força da sazonalidade (F_s), indicadores que quantificam o quanto a variação da série é atribuída a cada um desses componentes. Esses índices, que variam entre 0 e 1, auxiliaram na identificação de séries dominadas por estrutura forte ou por comportamento predominantemente aleatório, contribuindo para definir se modelos com tendência ou sazonalidade explícitas seriam recomendados (Hyndman & Athanasopoulos, 2024).

Após as análises estatísticas da série, procedeu-se à etapa de transformações com o objetivo de aprimorar a tratabilidade dos dados e, conseqüentemente, a qualidade das previsões. Inicialmente, aplicou-se a transformação logarítmica, recomendada quando a série apresenta variância crescente com o nível dos valores, permitindo estabilizar a dispersão e linearizar relações multiplicativas. Além disso, utilizou-se o método de *bootstrap*, que consiste em gerar réplicas da série por meio da reamostragem dos resíduos, preservando a estrutura temporal e possibilitando uma avaliação mais robusta da incerteza associada às previsões. Essas

transformações combinadas resultaram em uma série mais bem comportada para a modelagem, reduzindo efeitos de escala, heterocedasticidade e variações bruscas antes da aplicação dos modelos de previsão (Hyndman & Athanasopoulos, 2021).

3.4.2 Processamento

A partir da fundamentação estatística realizada e das transformações realizadas nas séries, foi possível selecionar modelos de previsão compatíveis com as características identificadas na série temporal do SKU analisado. Para isso, os modelos foram organizados em dois grupos: métodos clássicos de séries temporais e modelos de ML, permitindo avaliar abordagens estruturais e algoritmos baseados em aprendizado. Em seguida, esses modelos foram comparados entre si por meio de métricas de acurácia aplicadas na fase de teste, conforme recomendado por Hyndman e Athanasopoulos (2021). Entre as medidas utilizadas, destacam-se o MAE, RMSE, MAPE e sMAPE, que possibilitam avaliar o desempenho das previsões sob diferentes perspectivas. No entanto, a métrica principal adotada para julgamento dos modelos foi o MAE, por sua simplicidade interpretativa, robustez e adequação ao objetivo do estudo, permitindo determinar de forma clara qual método apresentava menor discrepância média em relação aos valores observados. Essa etapa consolidou a escolha do modelo mais apropriado para representar o comportamento futuro da série temporal analisada.

A definição do pipeline experimental foi orientada por práticas recomendadas na literatura de otimização de modelos, especialmente no que diz respeito à exploração estruturada de hiperparâmetros. Conforme discutido por Bergstra e Bengio (2012), a avaliação sistemática de múltiplas combinações é essencial para identificar configurações que maximizam o desempenho dos modelos, uma vez que diferentes parâmetros podem ter impactos distintos na qualidade das previsões e não há garantia teórica de que um conjunto específico seja superior a priori. Assim, o pipeline foi construído para percorrer de forma abrangente variações nos parâmetros dos modelos clássicos — como SARIMA — e dos modelos de aprendizado de máquina — como Random Forest e LSTM — permitindo comparar empiricamente seu comportamento diante da série analisada. Após a execução dos experimentos, o desempenho dos modelos foi avaliado na etapa de teste seguindo os critérios propostos por Hyndman e Athanasopoulos (2021), o que possibilitou selecionar o método mais consistente com base em evidências empíricas. Dessa forma, a escolha final do modelo decorreu de um processo de experimentação guiado por princípios robustos de busca por hiperparâmetros, alinhado às melhores práticas de previsão e machine learning.

Com a seleção do modelo mais adequado e a geração das previsões finais, encerra-se a etapa de processamento. As previsões obtidas constituem a base para a próxima fase do estudo, na qual as projeções de demanda serão utilizadas como insumo para o planejamento e controle da produção (PCP).

3.4.3 Pós-Processamento

No estágio de pós-processamento, Tubino (2009), Corrêa e Corrêa (2008) e Krajewski, Ritzman e Malhotra (2017) enfatizam que, após gerada a estimativa de demanda, é necessário determinar níveis de estoque, tamanhos de lote e políticas de reposição capazes de equilibrar custos de setup, manutenção e eventuais faltas. O pós-processamento, portanto, atua como ponte entre a previsão e o MPS, traduzindo informações probabilísticas em parâmetros operacionais concretos.

A definição do estoque de segurança é uma das etapas centrais desse processo, sendo amplamente tratada pela literatura como mecanismo de proteção contra incertezas. Os autores convergem no uso de abordagens baseadas na variabilidade da demanda ou do erro de previsão, associadas a um nível de serviço desejado — normalmente expresso por um fator z da distribuição normal. A estabilidade do sistema depende da calibragem adequada desse estoque de segurança, que deve considerar tanto o comportamento histórico da demanda quanto o *lead time* de reposição. Essa lógica fundamenta a solução adotada, em que o artefato calcula automaticamente o estoque de segurança variável por período com base no coeficiente de variação ou no desvio-padrão, conforme previsto na literatura (Slack; Chambers; Johnston, 2009; Tubino, 2009).

Outra dimensão essencial do pós-processamento é o dimensionamento de lotes, uma vez que o tamanho do lote afeta diretamente custos e disponibilidade de materiais. Os modelos clássicos, como lote econômico (EOQ/EPQ) e políticas Lote-a-Lote (L4L) ou Lote Fixo (FX), são amplamente utilizados para compatibilizar demanda, capacidade e custos operacionais. Esses modelos são incorporados ao artefato para definir, a partir da previsão e dos parâmetros fornecidos, as quantidades liberadas no MPS. Dessa forma, as decisões de reposição passam a refletir não apenas a demanda prevista, mas também os custos relevantes e a política de planejamento estabelecida pela empresa (Corrêa & Corrêa, 2008; Tubino, 2009).

3.5 Desenvolvimento do Artefato

3.5.1 Arquitetura Geral do Artefato

O artefato desenvolvido consiste em uma aplicação web construída em *Python* com a biblioteca *Streamlit* e disponibilizada em ambiente online através da hospedagem via *Streamlit Cloud*, integrando análise de dados, previsão de demanda e Planejamento e Controle da Produção (PCP). Sua arquitetura segue os princípios da *Design Science Research* (DSR), que orientam a construção de artefatos funcionais e avaliáveis. Para isso, o sistema foi organizado de forma modular, combinando páginas de interação com o usuário e módulos de processamento responsáveis pelas operações computacionais mais complexas (Dresch; Lacerda; Antunes, 2015).

As páginas *Streamlit* formam a camada de interface do artefato e estruturam o fluxo operacional do usuário, que avança pelas etapas de upload da série temporal, análise exploratória, geração da previsão, definição dos parâmetros de PCP, construção do MPS e visualização dos resultados. Embora organizadas sequencialmente, essas páginas dependem de variáveis armazenadas em “*st.session_state*”, que garante a integridade do fluxo e impede que etapas posteriores sejam acessadas sem que as anteriores tenham sido concluídas.

O processamento central é realizado pelos módulos “*Estatistica.py*”, “*pipeline.py*”, e “*mps.py*”. O primeiro produz diagnósticos da série temporal, como decomposição, tendência e detecção de *outliers*; o segundo executa e compara modelos de previsão, selecionando automaticamente o mais acurado; e o terceiro implementa o cálculo completo do MPS, incluindo estoque de segurança, políticas de lote, custos relevantes e indicadores como ATP. Esses módulos funcionam como componentes reutilizáveis chamados pelas páginas conforme necessário.

O fluxo de dados percorre o artefato de maneira integrada: a série carregada é tratada e analisada, utilizada para geração da previsão e, posteriormente, combinada com os parâmetros definidos pelo usuário para produzir o MPS. Essa arquitetura modular e interativa permite que o artefato mantenha coerência entre previsão, planejamento e análise gerencial, além de atender às diretrizes da DSR ao possibilitar ciclos iterativos de construção e avaliação.

3.5.2 Descrição dos Módulos

O artefato foi organizado em módulos funcionais correspondentes às páginas da aplicação *Streamlit*, complementados por rotinas de processamento implementadas em scripts de apoio. A comunicação entre os módulos ocorre por meio de variáveis armazenadas dentro do código, que garantem a integridade do fluxo e impedem o avanço para etapas posteriores sem que as anteriores tenham sido concluídas.

O módulo de menu (*Menu.py*) atua como ponto de entrada do sistema, apresentando a aplicação e disponibilizando a navegação entre as páginas. Embora o usuário possa acessar diretamente qualquer aba pela interface, cada módulo contém verificações internas que exigem a existência de informações mínimas em sessão (por exemplo, série carregada ou previsão gerada) para liberar a execução das rotinas principais.

O Módulo 01 – Upload da Série Temporal (*01_Upload.py*) recebe o arquivo de dados históricos, realiza a leitura, validação e padronização das colunas de data e quantidade e armazena a série.

Em seguida, o Módulo 02 – Série Temporal (*02_Serie_Temporal.py*) apresenta gráficos e estatísticas básicas, permitindo uma primeira inspeção visual do comportamento da demanda. Apresenta histograma e *Box-Plot* da série, assim como a decomposição da série para identificação de tendência, sazonalidade e qualidade dos dados.

O Módulo 03 – Análise Detalhada (*03_Analise_Detalhada.py*), é um módulo opcional para aqueles que tenham interesse em aprofundar a análise da série temporal avaliada. Ele é apoiado pelas funções do script “Estatistica.py”, apresentando um viés mais técnico com objetivo de explorar mais as características da série temporal.

O Módulo 04 – Previsão (*04_Previsao.py*), em conjunto com o script “*pipeline.py*”, executa o pipeline de modelos de previsão. Nessa etapa são testados diferentes métodos estatísticos e de ML, calculadas métricas de desempenho (como MAE, RMSE, MAPE e indicadores de viés) e selecionado automaticamente o modelo considerado mais adequado. A previsão resultante é armazenada e passa a funcionar como entrada principal para os módulos de Planejamento e Controle da Produção. Nesta etapa o usuário pode repetir o processo quantas vezes achar necessário.

O Módulo 05 – Inputs do MPS (*05_Inputs_MPS.py*) coleta os parâmetros necessários à construção do MPS. Nessa página, o usuário informa o estoque em mãos, os pedidos em carteira, política de lote, tamanho de lote, *lead time*, a configuração de congelamento do plano, se desejar, bem como os parâmetros econômicos para serem utilizados como base no cálculo do custo de *setup*, custo de manutenção, custo de ruptura do horizonte de planejamento. Também são definidos o método de cálculo do estoque de segurança (via coeficiente de variação ou desvio-padrão) e o nível de serviço desejado, que serão utilizados posteriormente no cálculo do MPS. Assim como na etapa anterior, o usuário poderá ajustar os parâmetros como quiser, simulando cenários e obtendo MPS a partir dele.

O Módulo 06 – MPS (*06_MPS.py*), sustentado pelo script “*mps.py*”, integra a previsão selecionada aos parâmetros de PCP para gerar o programa mestre de produção. O artefato calcula as principais linhas do MPS, conforme o modelo clássico: demanda prevista (Previsto), pedidos em carteira, Estoque Projetado, quantidade MPS (lotes planejados), Início MPS (ajustado pelo *lead time*) e ATP acumulado. As rotinas internas consideram o que foi definido pelo usuário no módulo anterior, além de prepararem os dados para exportação em planilha eletrônica e para uso no módulo de síntese.

Por fim, o Módulo 07 – *Dashboard de Conclusão* (*07_Dashboard_Conclusao.py*) reúne os resultados do artefato em uma visão gerencial. Essa página apresenta a comparação entre série histórica e previsão, o MPS consolidado, indicadores de acurácia e viés da previsão, comportamento de custos relevantes e análises sobre a capacidade de atendimento de novos pedidos com base no ATP. O módulo também oferece recursos de simulação, permitindo ao usuário avaliar o impacto de ajustes de parâmetros sobre o planejamento e os estoques.

3.5.3 Fluxos do Usuário

O fluxo operacional do artefato foi modelado utilizando duas abordagens distintas e complementares: *Business Process Model and Notation* (BPMN), para representar o processo de uso do sistema, e *Unified Modeling Language* (UML), para descrever a interação entre o usuário e as funcionalidades oferecidas. A combinação dessas representações permite visualizar não apenas a sequência lógica das atividades, mas também as dependências estruturais entre os módulos e as ações necessárias para transformar os dados históricos em decisões de planejamento da produção.

O diagrama BPMN mapeia todo processo do usuário dentro do artefato, desde o upload da série temporal até à visualização das recomendações geradas, evidenciando todos os caminhos e decisões que precisam ser tomadas.

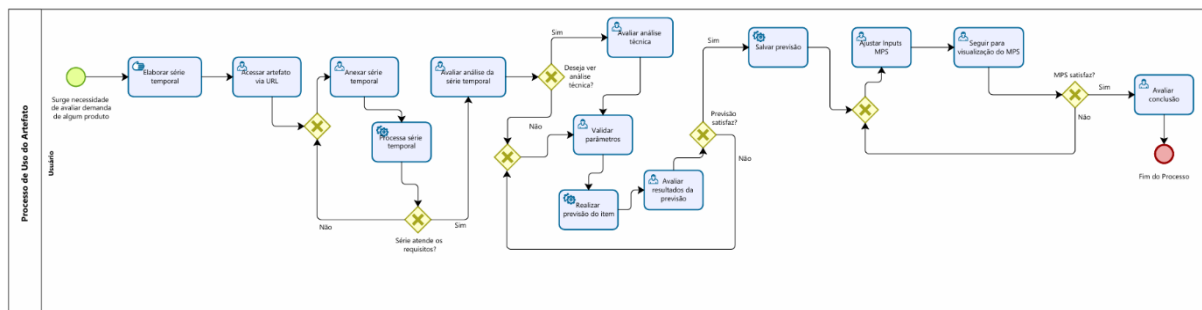


Figura 5: Mapeamento do Fluxo do Artefato

Fonte: Os autores (2025)

Complementarmente, o diagrama de casos de uso em UML representa a interação entre o ator principal, o usuário, e as funcionalidades centrais do sistema. O diagrama evidencia todas as ações realizadas pelo usuário, bem como as realizadas pelo sistema efetivamente.

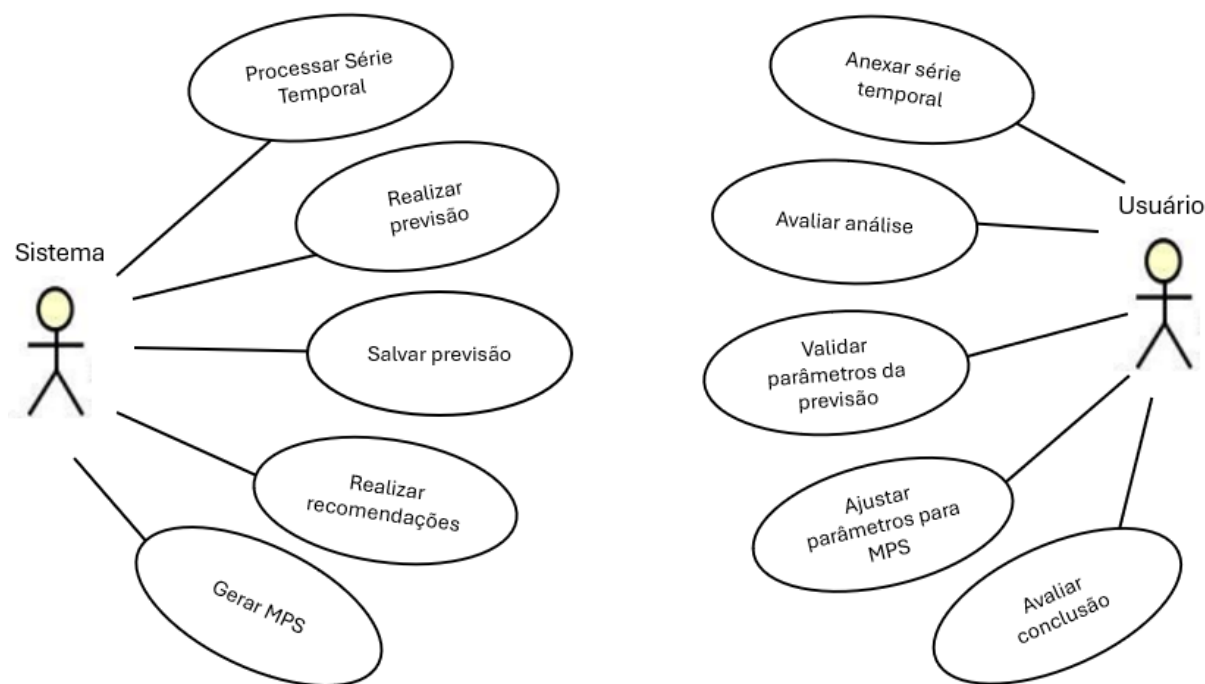


Figura 6: Diagrama de Caso de Uso

Fonte: Os autores (2025)

A utilização conjunta de BPMN e UML oferece uma visão abrangente e estruturada do funcionamento do artefato, tornando explícitas as etapas percorridas pelo usuário, os requisitos de cada módulo e as atividades.

3.6 Avaliação do Artefato

A avaliação do artefato proposto concentrou-se em verificar, de forma rigorosa, sua utilidade prática e aderência às necessidades da equipe usuária, observando como a ferramenta seria incorporada às rotinas de trabalho e qual relevância agregaria ao processo decisório. Em consonância com Lacerda et al. (2013), a etapa de avaliação deve considerar critérios previamente definidos — como clareza dos objetivos, coerência entre o ambiente interno do artefato e o ambiente externo onde ele opera, e a capacidade de o artefato gerar resultados satisfatórios para o problema em questão. Assim, buscou-se avaliar se a solução desenvolvida era compreensível, operacionalizável e efetiva para os usuários, bem como se cumpria os requisitos funcionais esperados. Além disso, foram considerados aspectos qualitativos relacionados à experiência dos avaliadores, alinhando-se ao entendimento de que a validade pragmática do artefato depende tanto de seu desempenho técnico quanto da percepção de sua aplicabilidade no contexto real de uso.

Para conduzir a avaliação observacional e experimental do artefato, foram realizados testes utilizando bases reais da empresa de manufatura estudada, de modo a verificar seu comportamento em condições próximas ao ambiente operacional. Esses testes foram acompanhados por dois avaliadores-chave: o gerente de TI, profissional com mais de 20 anos de experiência em soluções tecnológicas, responsável por analisar a robustez técnica, a arquitetura e a operacionalidade do artefato; e a gerente de operações, cuja atuação incluiu julgar a aplicabilidade prática da ferramenta no cotidiano do PCP, avaliando sua aderência às rotinas e sua capacidade de apoiar decisões de planejamento. Essa configuração segue as recomendações de Lacerda et al. (2013), que destacam a importância de envolver especialistas tanto no domínio tecnológico quanto no domínio do problema para fortalecer a validade pragmática do artefato e assegurar que ele seja eficaz e relevante no contexto real de uso.

3.7 Conclusão e Comunicação dos Resultados

A comunicação dos resultados do artefato seguiu os princípios da *Design Science Research*, priorizando acessibilidade, clareza e disseminação do conhecimento produzido. A solução desenvolvida foi disponibilizada ao público por meio de uma aplicação web hospedada

na plataforma *Streamlit Cloud*, acessível diretamente via URL ([Link para acesso](#)), permitindo que gestores, pesquisadores e demais interessados utilizem o protótipo sem necessidade de instalação local. Essa forma de disponibilização favorece a interação com as funcionalidades do sistema — como análise da série temporal, geração da previsão e cálculo do MPS — e amplia o alcance da ferramenta, tornando possível sua demonstração e aplicação em diferentes contextos.

Além disso, o artefato foi apresentado formalmente à empresa parceira do projeto, viabilizando sua utilização prática como ferramenta de apoio às decisões de previsão de demanda e planejamento da produção. A disponibilização do sistema por meio da URL facilita sua incorporação em processos internos e permite que a organização experimente cenários, avalie parâmetros e explore o potencial do protótipo em integrar previsão e PCP. Por fim, os resultados e a arquitetura da solução foram comunicados à banca avaliadora durante a apresentação da monografia, consolidando a validação acadêmica do artefato e reforçando sua contribuição teórica, prática e metodológica.

4 RESULTADOS E DISCUSSÃO

4.1 Descrição do caso e da empresa

A empresa analisada neste estudo de caso é uma indústria moveleira especializada na fabricação de mobiliário escolar. Seu portfólio é voltado principalmente para instituições de ensino, atendendo desde escolas e universidades até centros educacionais variados. Como empresa de manufatura, opera com processos produtivos estruturados e uma linha de produtos que exige padronização, eficiência operacional e capacidade de resposta à demanda. A escolha dessa organização permitiu explorar, de forma prática, os desafios e oportunidades do planejamento e controle da produção em um contexto real de manufatura seriada voltada ao setor educacional.

Para compreender a fundo o funcionamento do caso e definir a forma de atuação, foram realizadas entrevistas e visitas técnicas à empresa, permitindo observar de perto a rotina da área de PCP. Essas interações evidenciaram uma lacuna significativa no planejamento futuro, que era conduzido majoritariamente com base na experiência dos profissionais. Embora a equipe possuísse conhecimento intuitivo sobre os movimentos sazonais do mercado ao longo do ano, as decisões não eram sustentadas por dados estruturados. Diante desse cenário, identificamos que a melhor contribuição seria o desenvolvimento de um artefato capaz de prever a demanda, oferecendo subsídios quantitativos para o planejamento. Além disso, integramos essa previsão a ferramentas de PCP, como o MPS, permitindo que os gestores realizassem um planejamento mais robusto, fundamentado em dados e alinhado às práticas modernas utilizadas no mercado.

A delimitação do estudo concentrou-se nos principais produtos do portfólio associados ao ensino básico e superior, cuja demanda apresenta variações significativas ao longo do ano, especialmente em períodos de renovação de matrículas e reformas escolares. A empresa demonstrou interesse no projeto devido à necessidade de aprimorar sua capacidade de planejamento e reduzir incertezas relacionadas à compra de materiais, alocação de recursos e definição da capacidade produtiva.

4.2 Aplicação do protótipo no caso

Para demonstrar a aplicação prática do protótipo desenvolvido, selecionamos duas séries temporais a partir do pré-processamento descrito na metodologia. A primeira corresponde ao produto de maior relevância no faturamento da empresa, permitindo analisar a previsão de demanda de um item individual de alta representatividade. A segunda consiste em uma série

agregada formada pela combinação de três produtos distintos, construída com o objetivo de avaliar o comportamento conjunto desses itens ao longo do tempo. É importante destacar que, por se tratar de uma agregação, essa segunda série não foi submetida ao MPS, uma vez que a lógica do planejamento mestre de produção exige a análise individualizada dos produtos, conforme previsto em sua metodologia.

4.2.1 Antes do uso do artefato

Antes da utilização do artefato, partimos de uma base completa contendo toda a demanda registrada pela empresa desde 2017. Para organizar esse conjunto de dados e identificar padrões relevantes, aplicamos um processo de clusterização utilizando a metodologia *k-means*, agrupando os produtos em três categorias: baixo volume, com 259 produtos; médio volume, com 194 produtos e alto volume, composto por 95 produtos. A partir desses agrupamentos, concentramos a análise nos itens de alto volume e aplicamos a classificação ABC para identificar os produtos mais representativos dentro desse cluster. Esse processo permitiu localizar o item de maior relevância no faturamento, classificado como “A” e identificado pelo código 7, que se destacou como o produto principal da empresa. A seguir, são apresentadas as imagens contendo os resultados obtidos pelas metodologias de clusterização e classificação ABC, respectivamente:

Cluster	Quantidade de tipos Produtos
Baixo Volume	259
Médio Volume	194
Alto Volume	95

Figura 7: Resultado da Clusterização

Fonte: Os autores (2025)

ID	Nome do Cluster	Valor Usado	Porcentagem	Porcentagem Acumulada	Classificação
7	Alto Volume	458577,5594	20,46%	20,46%	A
33	Alto Volume	419665,0903	18,73%	39,19%	A
26	Alto Volume	333267,1322	14,87%	54,06%	A
346	Alto Volume	259640,3557	11,59%	65,64%	A
6	Alto Volume	97871,98882	4,37%	70,01%	A
19	Alto Volume	91463,46136	4,08%	74,09%	A
32	Alto Volume	80196,78179	3,58%	77,67%	A
2	Alto Volume	78293,21483	3,49%	81,16%	B
5	Alto Volume	66789,71408	2,98%	84,14%	B
3	Alto Volume	52141,43141	2,33%	86,47%	B

Figura 8: Resultado da Classificação ABC

Fonte: Os autores (2025)

4.2.2 Primeiros passos dentro do artefato

Para iniciar o uso do artefato, carregamos as duas séries temporais selecionadas — a série real correspondente ao principal SKU, reconhecida como série 1, e uma série temporal artificial criada exclusivamente para fins de experimentação — diretamente pelo módulo de upload da aplicação. Seguindo Lacerda et al. (2013), a utilização de dados artificiais é fundamental para realizar análises experimentais controladas, permitindo avaliar a robustez e o comportamento do artefato em cenários livres das imperfeições presentes nos dados reais. Após navegar pelo menu inicial, o usuário acessa a área destinada ao carregamento dos dados históricos, onde o artefato realiza automaticamente a padronização das colunas e armazena as informações necessárias para as etapas seguintes. Esse primeiro passo garante que ambas as séries estejam devidamente estruturadas no ambiente da aplicação, possibilitando avançar para as avaliações estatísticas, inspeções visuais e demais funcionalidades disponibilizadas nos módulos posteriores.



Figura 9: Carregamento da Série Temporal

Fonte: Os autores (2025)

4.2.3 Resultados – Análise Série Temporal e Previsão

Na etapa seguinte, o artefato apresenta a visualização completa das duas séries temporais carregadas, permitindo uma leitura imediata das diferenças estruturais entre elas. A

série artificial exhibe um comportamento estável e bem-comportado, com tendência suave de crescimento, variabilidade moderada (CV de 17,3%) e ausência de valores extremos — características confirmadas tanto pelo gráfico de linha quanto pelas estatísticas descritivas, que mostram média e mediana praticamente iguais e nenhum valor faltante ou discrepante. Em contraste, a série real do SKU apresenta uma dinâmica bastante irregular, marcada por picos muito elevados, quedas abruptas e um coeficiente de variação extremamente alto (125,6%), refletindo sua assimetria e elevada dispersão. O gráfico mensal evidencia essa instabilidade, com oscilações intensas ao longo do período, e os valores de mínimo e máximo mostram uma amplitude expressiva. Essa visualização conjunta permite ao usuário compreender, desde o início, como a série artificial funciona como um cenário controlado para experimentação, enquanto a série real impõe desafios típicos de dados empresariais, reforçando a importância de comparar o desempenho do artefato em contextos contrastantes.



Figura 10: Análise Exploratória, Série Real x Série Artificial

Fonte: Os autores (2025)

A visualização estatística complementa a compreensão das diferenças estruturais entre as séries. Na série artificial, o histograma apresenta distribuição relativamente uniforme e concentrada, refletindo valores estáveis e ausência de caudas longas. O *box-plot* mensal reforça essa estabilidade, com intervalos interquartis próximos, poucas variações entre meses e inexistência de *outliers* relevantes. Os gráficos de tendência e sazonalidade mostram exatamente o comportamento esperado para dados sintéticos: tendência linear suave e sazonalidade regular, simétrica e altamente previsível. Em contraste, a série real exhibe um histograma assimétrico e fortemente concentrado em valores baixos, acompanhado de uma longa cauda que se estende até demandas superiores a 9.000 unidades — evidência clara de picos abruptos e comportamento errático. O *box-plot* mensal torna essa instabilidade ainda mais evidente, com forte dispersão, presença de múltiplos *outliers* e uma variação expressiva entre meses. A tendência apresenta queda acentuada ao longo dos anos, enquanto a componente

sazonal revela oscilações intensas e irregulares. Em conjunto, esses gráficos mostram como a série artificial funciona como referência controlada, enquanto a série real apresenta grande complexidade, elevada variabilidade e comportamento desafiador para modelagem preditiva.

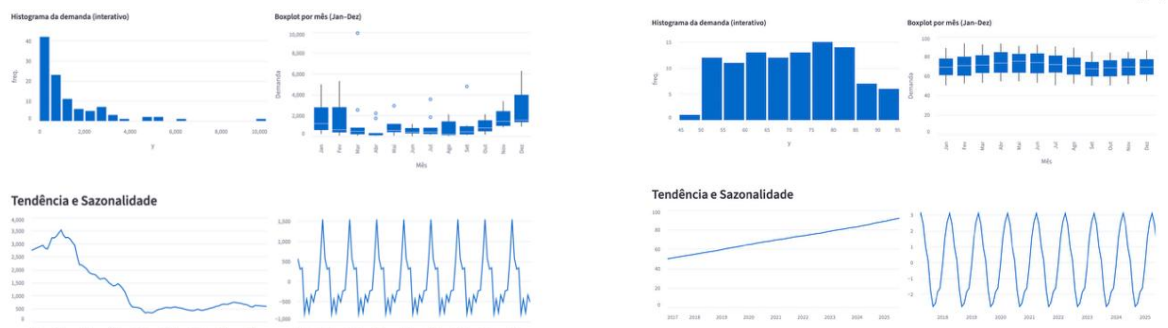


Figura 11: Análise Gráfica, Série Real x Série Artificial

Fonte: Os autores (2025)

Além disso, o artefato identifica automaticamente *outliers* pelo método interquartilico (IQR), ainda na etapa de análise exploratória. Os resultados reforçam o contraste entre as séries: a série artificial não apresenta nenhum valor extremo, enquanto a série real possui seis *outliers*, todos associados a picos elevados de demanda. Essa verificação rápida de qualidade dos dados ajuda o usuário a reconhecer a maior instabilidade da série real antes de avançar para a etapa de modelagem.

Qualidade dos Dados

Dados faltando (originais): 0

Outliers (IQR, após imputação): 6 ocorrência(s) (limiaries: baixo < -1985.9 | alto > 3853.1 — Q1=203.8, Q3=1663.5, IQR=1459.8).

Figura 12: Identificação de Outliers, Série Real

Fonte: Os autores (2025)

Qualidade dos Dados

Dados faltando (originais): 0

Outliers (IQR, após imputação): 0 ocorrência(s) (limiaries: baixo < 30.2 | alto > 111.2 — Q1=60.6, Q3=80.8, IQR=20.3).

Figura 13: Identificação de Outliers, Série Artificial

Fonte: Os autores (2025)

A seguir, o artefato disponibiliza a etapa de análise detalhada, um módulo opcional voltado para usuários que desejam aprofundar o diagnóstico estatístico da série temporal. Nessa página, o usuário pode ajustar parâmetros como a quantidade de *lags* utilizados nos cálculos de

autocorrelação e nos testes formais. O artefato aplica três grupos principais de verificações: (1) tipo de demanda, utilizando as métricas ADI e CV^2 para classificar a série como regular, intermitente, errática ou irregular; (2) heterocedasticidade, avaliada a partir da relação entre nível e variação da série e de testes baseados em regressões auxiliares; e (3) assimetria e positividade, examinadas por meio do coeficiente de *skewness* e pela detecção de valores menores ou iguais a zero, que orientam a necessidade de transformações como log ou Box–Cox. Nos resultados observados, a série artificial apresenta comportamento regular, baixa variabilidade relativa, assimetria praticamente nula e sinal de heterocedasticidade leve e estável. Já a série real exibe CV^2 elevado, forte assimetria positiva e variância crescente ao longo do tempo, sendo classificada como errática — um indicativo claro de maior complexidade e maior necessidade de transformações antes da modelagem preditiva.

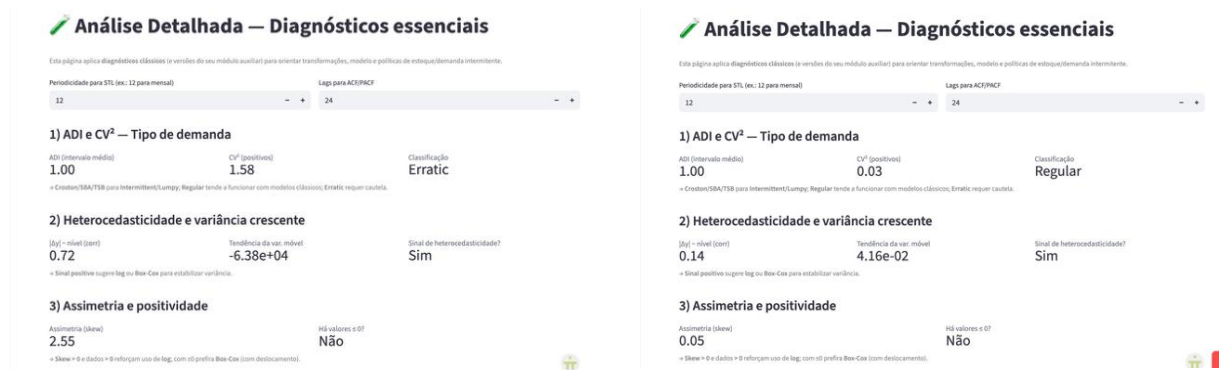


Figura 15: *Análise Detalhada (Parte 1), Série Real x Série Artificial*

Fonte: Os autores (2025)

Na sequência da análise detalhada, o artefato apresenta diagnósticos adicionais relacionados à decomposição STL, testes de estacionariedade e recomendação de transformação Box–Cox. A força da tendência e da sazonalidade é estimada segundo Hyndman e Athanasopoulos (2021), permitindo ao usuário compreender a contribuição de cada componente na série. Em seguida, são aplicados os testes ADF e KPSS, que verificam estacionariedade sob hipóteses opostas e fornecem um diagnóstico combinado mais robusto,

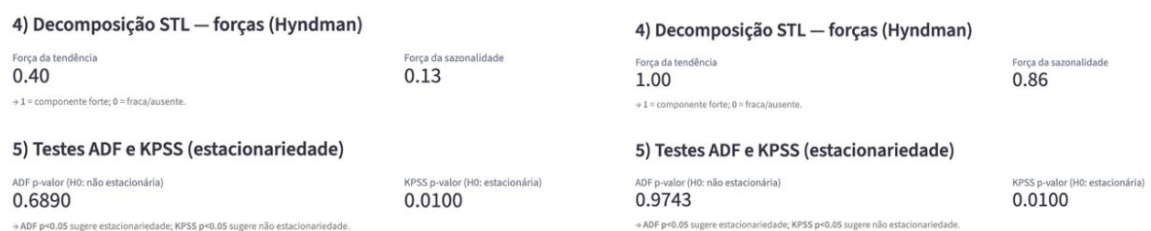


Figura 14: *Análise Detalhada (Parte 2), Série Real x Série Artificial*

Fonte: Os autores (2025)

conforme descrito no referencial teórico. Por fim, o artefato estima o parâmetro λ da transformação Box–Cox via máxima verossimilhança, indicando se a estabilização de variância é necessária. Nos resultados, a série artificial apresenta tendência forte (1.00), sazonalidade pronunciada (0.86) e valores de ADF e KPSS que confirmam não estacionariedade, além de um λ intermediário (0.63), sugerindo leve transformação. Já a série real exibe tendência fraca (0.40), sazonalidade baixa (0.13), confirmação de não estacionariedade pelos testes e λ muito próximo de zero (0.15), indicando alta necessidade de transformação para estabilizar a variância.

Por fim, a análise detalhada apresenta os gráficos de autocorrelação (FAC) e autocorrelação parcial (FACP), que permitem identificar padrões de dependência serial na série. A FAC revela a persistência dos efeitos ao longo dos lags, enquanto a FACP mostra quais defasagens exercem influência direta, auxiliando na identificação de estruturas AR, MA ou ARMA/ARIMA. A série artificial exibe uma autocorrelação que decai lentamente, característica de séries não estacionárias com forte componente de tendência e sazonalidade. Já a série real apresenta correlações mais irregulares e dispersas, coerentes com seu comportamento errático e de alta variabilidade. Com base em todos os resultados obtidos na análise detalhada, o artefato gera automaticamente um conjunto de recomendações, indicando transformações, tipos de modelos mais adequados, tratamento de heterocedasticidade, necessidade de diferenciação ou suavização e cuidados com sazonalidade — orientando o usuário de forma prática sobre os próximos passos antes da etapa de previsão.

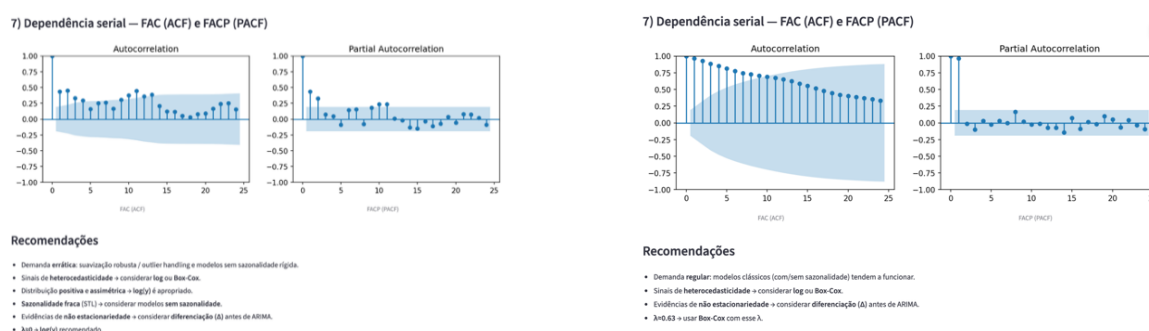


Figura 16: Análise Detalhada (Parte Final), Série Real x Série Artificial

Fonte: Os autores (2025)

Na etapa de Previsão, o usuário define os parâmetros que orientarão a geração dos modelos e das projeções. O primeiro ajuste disponível é o horizonte de previsão, que pode ser configurado para 6, 8 ou 12 meses, lembrando que horizontes mais longos tendem a reduzir a

precisão das estimativas. Em seguida, o usuário pode ativar ou não diferentes formas de pré-processamento, de acordo com as recomendações obtidas na análise detalhada anterior. Entre essas escolhas estão a aplicação da transformação logarítmica, indicada para séries com heterocedasticidade ou assimetria, e a utilização do *bootstrap*, que amplia a robustez da busca pelo melhor modelo ao gerar múltiplas réplicas da série temporal. O artefato também permite definir o número de réplicas utilizadas no *bootstrap* — quanto maior esse número, maior a chance de encontrar um ajuste superior, embora o processo se torne mais lento. O valor padrão definido pela aplicação é de 20 réplicas, configuração utilizada para todas as análises apresentadas. Ademais, para iniciar o processo de previsão, basta o usuário clicar em “Rodar previsão”, após escolher tais parâmetros.

Na etapa de execução da previsão, o artefato testa automaticamente um conjunto de modelos e combinações de hiperparâmetros definidos em um grid estruturado. Os modelos avaliados incluem Croston, SBA, TSB, Random Forest, SARIMA e LSTM, cada um selecionado para refletir diferentes padrões identificados na análise detalhada. O grupo Croston/SBA/TSB foi incluído devido à alta variabilidade e ao comportamento errático da série real, características que tornam esses métodos adequados para demandas irregulares e intermitentes. O Random Forest contribui pela flexibilidade em capturar relações não lineares a partir de múltiplos tamanhos de defasagem. O SARIMA é testado por sua robustez em séries com estrutura temporal clássica, permitindo modelar dependências autorregressivas, sazonais e de médias móveis. Por fim, o LSTM foi incorporado por sua capacidade de aprender padrões complexos de longo prazo, sendo especialmente útil quando a série apresenta comportamento não linear, ruído elevado ou relação temporal de maior profundidade.

Os hiperparâmetros de cada modelo foram definidos em faixas coerentes com a literatura e calibradas para equilibrar desempenho e custo computacional. No Croston, SBA e TSB, variam-se alphas e betas para diferentes graus de suavização; no Random Forest, testam-se combinações de número de estimadores, profundidade máxima e lags; no SARIMA, o *grid* considera pequenas variações em (p,d,q) e (P,D,Q) para evitar superparametrização; e no LSTM, utilizamos uma arquitetura compacta — com número reduzido de neurônios e épocas suficientes para convergência — a fim de garantir boa performance sem comprometer o tempo de processamento. Assim, a previsão é construída sobre uma busca sistemática e equilibrada

entre modelos tradicionais e modernos, garantindo representatividade das características observadas nas séries.

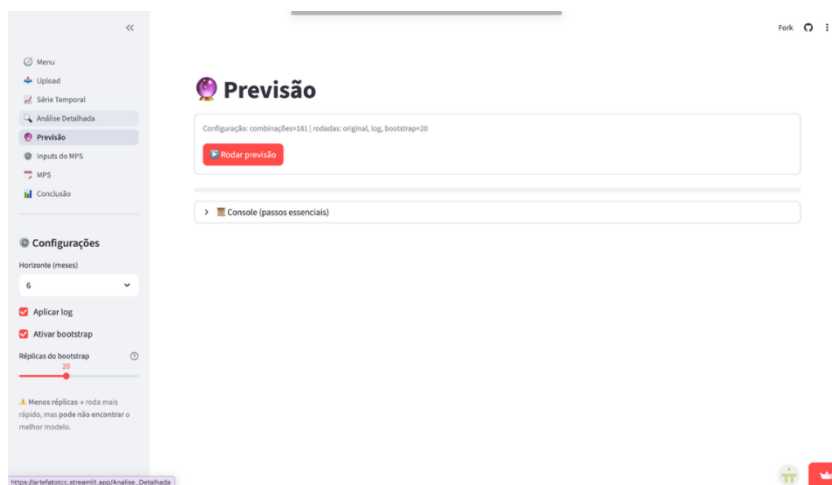


Figura 17: Etapa de Previsão

Fonte: Os autores (2025)

Ao rodar a previsão, o artefato executa automaticamente todos os modelos definidos e percorre cada combinação de hiperparâmetros nas fases de treinamento e teste, buscando aquele que produz o menor MAE dentro da amostra — métrica adotada para determinar o modelo campeão. Após encontrar o melhor ajuste, a aplicação apresenta ao usuário o modelo vencedor, seus hiperparâmetros e a previsão fora da amostra. Para a série real, o melhor desempenho foi obtido pelo SARIMA (2,0,0)(1,0,0,12), utilizando *bootstrap* na réplica 10, configuração coerente com sua elevada variabilidade e comportamento errático. Já na série artificial, o modelo campeão foi o SARIMA (0,1,0)(1,1,0,12), também rodado com *bootstrap* na réplica 15, refletindo um cenário mais estável, com tendência e sazonalidade bem definidas que favorecem modelos clássicos e previsões mais consistentes.



Figura 18: Resultado das Previsões, Série Real x Série Artificial

Fonte: Os autores (2025)

Ao final da etapa de previsão, o usuário tem ainda a opção de baixar um arquivo contendo todos os experimentos realizados, permitindo consultar cada combinação de modelo e hiperparâmetro testada pelo artefato. Além disso, apresenta-se a seguir duas tabelas com os melhores desempenhos dos demais modelos de previsão avaliados para cada uma das séries:

Modelo de previsão	Pré-processamento	Hiperparâmetros	MAE
Sarima	<i>Bootstrap</i>	(2,0,0)x(1,0,0,12)	36,41
<i>Croston</i>	<i>Bootstrap</i>	$\alpha = 0,5$	199,17
<i>SBA</i>	<i>Bootstrap</i>	$\alpha = 0,5$	137,45
<i>TSB</i>	<i>Bootstrap</i>	$\alpha = 0,5; \beta = 0,1$	199,17
<i>Random Forest</i>	<i>Bootstrap</i>	$N_estimators = 200;$ $Lags = 1...12;$ $Max_depth = None$	137,50
<i>LSTM</i>	Logaritmo	$Window = 12; epochs = 30;$ $Batch = 16;$ $Units = 64$	252,64

Tabela 2: Melhores resultados para cada modelo na série real

Fonte: Os autores (2025)

Modelo de previsão	Pré-processamento	Hiperparâmetros	MAE
Sarima	Bootstrap	(0,1,0)x(1,1,0,12)	0,32
Croston	Bootstrap	$\alpha = 0,5$	0,56
SBA	Bootstrap	$\alpha = 0,1$	6,97
TSB	Bootstrap	$\alpha = 0,5; \beta = 0,1$	0,56
Random Forest	Bootstrap	$N_estimators = 200;$ $Lags = 1...12;$ $Max_depth = None$	0,65
LSTM	Bootstrap	$Window = 6; epochs = 30;$ $Batch = 16;$ $Units = 64$	0,51

Tabela 3: Melhores resultados para cada modelo na série artificial

Fonte: Os autores (2025)

Assim, para avançar no fluxo da aplicação, basta clicar em “Salvar previsão”, garantindo que o modelo campeão e suas estimativas sejam registrados. Somente após esse passo a próxima etapa é habilitada, permitindo que o usuário utilize os resultados para dar continuidade ao planejamento de produção (PCP) dentro das ferramentas integradas do artefato.

4.2.4 Resultados – Gestão de estoque

A aba *Inputs do MPS* reúne todos os parâmetros necessários para que o usuário configure o MPS de acordo com as características operacionais do item analisado. É nessa etapa que o artefato recebe as informações fundamentais para gerar o MPS, permitindo que políticas de lote, estoque inicial, pedidos firmes, horizonte congelado e parâmetros de custo sejam definidos antes da execução do cálculo. No cenário base utilizado neste trabalho, o item planejado é a *Cadeira Escolar Adulto*, com política de lote fixo e tamanho de lote de 500 unidades, acompanhado de um estoque inicial de 150 unidades. Essas informações constituem a configuração padrão do artefato e orientam a geração do plano apresentado nos cenários seguintes.



Inputs do MPS

Horizonte atual da Previsão: 6 meses.

1) Item e políticas padrão

Item (nome)	Política padrão	Tamanho do lote padrão (se FX)	Estoque em mão inicial (padrão)
Cadeira Escolar Adulto	Lote Fixo (FX)	500	150

Lead time (meses)

1

Figura 19: Inputs Operacionais MPS – Cenário Base

Fonte: Os autores (2025)

O usuário também pode configurar parâmetros relacionados ao estoque de segurança, definindo se usará o cálculo variável (com base no coeficiente de variação ou desvio padrão) ou estático, seguindo o nível de serviço determinado. No cenário base, ativamos o estoque de segurança automático, utilizando o método do coeficiente de variação, a uma taxa de 15 % demanda/erro.

2) Estoque de segurança — parâmetros

☒ Ativar SS automático (variável por mês)

Nível de serviço (z) 95% ▼

CV da demanda/erro (%) 15,00 - +

Método

☒ CV (%) ☐ σ absoluto

Figura 20: Estoque de Segurança – Cenário Base

Fonte: Os autores (2025)

Além disso, o sistema oferece a possibilidade de ativar um período de congelamento do horizonte, impedindo alterações nas primeiras semanas ou meses do planejamento. Para os resultados apresentados, essa opção foi mantida desativada no cenário base.

3) Congelamento de horizonte (intervalo)

☐ Ativar congelamento

Período congelado: sem congelamento

Figura 21: Congelamento de Horizonte – Cenário Base

Fonte: Os autores (2025)

A aba também permite a edição dos pedidos firmes já em carteira, que influenciam diretamente a necessidade líquida e o momento em que as ordens são liberadas. No cenário base, os pedidos registrados contemplam o período de setembro de 2025 a fevereiro de 2026, com valores entre 80 e 150 unidades por mês, refletindo uma demanda institucional típica do setor de interesse.

4) Pedidos firmes — Em carteira

	Set/25	Out/25	Nov/25	Dez/25	Jan/26	Fev/26
Em carteira	120	80	150	90	100	140

Figura 22: Pedidos firmes – Cenário Base

Fonte: Os autores (2025)

Por fim, o usuário insere os parâmetros econômicos utilizados posteriormente na análise de custos, incluindo o custo de setup ($A = R\$ 300$), a taxa de produção ($p = 2.500$ un/mês), o valor unitário do item ($R\$ 100$), o custo de manter estoque ($R\$ 2,50$ por unidade/mês) e o custo de falta ($R\$ 30$ /unidade). Esses valores compõem integralmente o cenário base e funcionam como referência para todas as análises de sensibilidade desenvolvidas nas seções seguintes.

5) Parâmetros de custos

Base de tempo dos parâmetros (para D, H e π): ?

☒ por mês ☐ por ano

A — Custo fixo por setup (R\$) ? 300,00 - +

D — Taxa de demanda (unid/mês) ? 233,41 - +

p — Taxa de produção (unid/mês) ? 2500,00 - +

Como deseja informar H?

☒ Informar H diretamente ☐ Calcular H a partir de r e v

v — Valor unitário do item (R\$/unid) (obrigatório) ? 100,00 - +

H — Custo de manter (R\$ por unid/mês) ? 2,50 - +

π — Custo de falta/ruptura (R\$ por unidade não atendida) ? 30,00 - +

Figura 23: Parâmetros de Custos – Cenário Base

Fonte: Os autores (2025)

Todo esse conjunto de informações forma a base sobre a qual o artefato constrói o MPS, permitindo que o usuário visualize o impacto de diferentes configurações nos resultados operacionais e econômicos do planejamento. Ao finalizar o cadastro de todas as informações o usuário deve clicar no botão “Salvar inputs do MPS”, que retornará a seguinte mensagem:

Salvar inputs do MPS

Inputs do MPS salvos com sucesso! ✓

Retornar para Previsão Ir para MPS (Plano Mestre de Produção)

Figura 24: Mensagem de Confirmação

Fonte: Os autores (2025)

Essa mensagem mostrará que o usuário está pronto para seguir para visualização do MPS e, por fim, as recomendações geradas automaticamente com base em tudo que foi registrado dentro do artefato ao longo do seu processo.

Ao seguir para a página seguinte, o usuário consegue visualizar o quadro efetivamente com tudo que foi definido no módulo anterior. Para o cenário base construído, chegamos no seguinte plano de produção:

MPS — Visualização Mensal

	Set/25	Out/25	Nov/25	Dez/25	Jan/26	Fev/26
Previsto	87	370	287	375	150	133
Em carteira	120	80	150	90	100	140
Estoque Proj.	63	193	406	531	381	248
Qtde. MPS	0	500	500	500	0	0
Início MPS	500	500	500	0	0	0
ATP(cum)	0	270	530	700	700	700

Figura 25: MPS - Cenário Base

Fonte: Os autores (2025)

Dentro desta mesma página, o usuário poderá observar quais foram os parâmetros aplicados para construção do MPS, aqueles definidos na página anterior. Bem como exportar o MPS gerado em formato de planilha eletrônica. Após validação completa do MPS, usuário poderá seguir para conclusão do artefato, que falaremos na próxima seção.

4.2.5 Resultados – Recomendações

A aba de *Recomendações* tem como objetivo apresentar ao usuário um painel consolidado de diagnóstico, permitindo interpretar rapidamente os resultados gerados pelo artefato e tomar decisões embasadas tanto na previsão quanto no MPS. Esse painel funciona como um ambiente de apoio à decisão, reunindo informações sobre acurácia, vieses, custos, capacidade de atendimento (ATP) e impactos de alterações paramétricas. A seguir, descrevem-se os principais resultados exibidos em cada uma das subseções deste módulo, acompanhados das respectivas visualizações.

A primeira parte apresenta o desempenho do modelo de previsão selecionado pelo artefato como o mais adequado. O sistema exibe o modelo campeão, seus parâmetros ajustados e o comportamento da previsão frente aos valores reais da série. O gráfico resultante permite avaliar visualmente a aderência entre previsto e realizado, destacando oscilações, períodos de maior discrepância e estabilidade temporal.



Figura 26: Real + Projetado - Cenário Base

Fonte: Os autores (2025)

Em seguida, o painel disponibiliza as métricas de desempenho associadas ao modelo escolhido, incluindo MAE, sMAPE, RMSE e MAPE. Esses indicadores são apresentados de forma numérica e acompanhados de uma interpretação automática, facilitando a leitura por parte do usuário. O artefato ainda contextualiza o significado desses valores, destacando que erros elevados podem decorrer de características próprias da série, como sazonalidade irregular ou comportamento intermitente.



Figura 27: Métricas de Desempenho da Previsão - Cenário Base

Fonte: Os autores (2025)

Na subseção seguinte, o sistema apresenta o diagnóstico de vieses da previsão. São exibidos o viés médio absoluto, o viés percentual e o MAE no período de *backtest*, permitindo identificar se o modelo tende sistematicamente a superestimar ou subestimar a demanda. O gráfico complementar mostra a evolução do erro ao longo do tempo, destacando períodos em que o sinal se mantém positivo ou negativo e possíveis padrões de desbalanceamento.



Figura 28: Painel com Informações sobre o Viés - Cenário Base

Fonte: Os autores (2025)



Figura 29: Gráfico Representando Viés da Série Temporal - Cenário Base

Fonte: Os autores (2025)

O painel também apresenta um resumo dos custos associados ao MPS, considerando os parâmetros definidos na etapa de inputs. São mostrados o custo de setup, o custo de manter, o custo de ruptura e o custo total relevante, todos calculados a partir da política de produção do cenário base. Essa visualização facilita compreender o impacto econômico das decisões tomadas e serve como referência para análises posteriores de sensibilidade.

✓ Conclusão (Painel de Decisão)

 Acurácia
  Viéses
  MPS & KPIs
  Recomendações

MPS — Custos e Resumo (somente leitura dos inputs)

>  Variáveis (05_Inputs_MPS) e parâmetros usados

Custo de setup (R\$) ⓘ

840,27

FX (mensal × 6)

Custo de ruptura (R\$) ⓘ

0,00

$\Sigma(\text{Ruptura}) \times \pi$

Custo de manter (R\$) ⓘ

3.399,89

FX (mensal × 6)

Custo total relevante ⓘ

4.240,16

Setup + Manter + Ruptura

Figura 30: Custos do MPS - Cenário Base

Fonte: Os autores (2025)

Além disso, o módulo exibe o comportamento do ATP acumulado ao longo dos meses, permitindo avaliar a capacidade de atendimento considerando a disponibilidade futura resultante do MPS. O gráfico e a tabela associados mostram o nível de ATP em cada mês e indicam se haveria ou não capacidade para absorver uma demanda extra hipotética inserida pelo usuário. Essa funcionalidade auxilia na visualização do grau de folga operacional do sistema.

ATP acumulado (até cada mês)

Demanda extra hipotética (un/mês)

300

ATP acumulado vs. demanda extra (fixa) (extra = 300 un/mês)



Com 300 un/mês de demanda extra, os meses atendidos são: Nov/25, Dez/25, Jan/26, Fev/26.

Figura 31: ATP Acumulado

Fonte: Os autores (2025)

Por fim, a seção apresenta o módulo de simulação das mudanças dos parâmetros econômicos no Custo Relevante Total, que permite testar o impacto de alterações nos principais parâmetros do modelo, como demanda média, capacidade produtiva, custo de *setup*, custo de manter e tamanho de lote. O usuário pode ajustar esses valores diretamente no painel, e o sistema recalcula imediatamente o custo relevante total, a curva $C(Q)$ e a comparação com o MPS original. Esse recurso permite explorar cenário alternativos e visualizar seu efeito econômico de forma rápida.

Horizonte de comparação travado em 6 meses (igual ao da previsão).

Demanda média (unid/mês)	Capacidade p (unid/mês)	Custo de setup A (R\$)	Custo de manter H (R\$/un-mês)
233,41	2500,00	300,00	2,50
Q — Tamanho do lote (unid)	SS adicional (unid/mês) (opcional)		
500	0		

Figura 32: Painel de Controle dos Parâmetros

Fonte: Os autores (2025)




Figura 33: Custos da Simulação e Curva da Sensibilidade

Fonte: Os autores (2025)

4.3 Análise de sensibilidade

Esta seção de análise de sensibilidade tem como objetivo avaliar como variações em certos parâmetros do artefato permitem visualização de diferentes cenários, que influenciam diretamente os resultados gerados pelos módulos de planejamento (MPS), disponibilidade para promessas (ATP) e custos operacionais. A partir de cenários hipotéticos, busca-se demonstrar

a robustez do sistema e sua capacidade de apoiar decisões em ambientes sujeitos a incerteza, permitindo ao usuário compreender quais variáveis exercem maior impacto nas decisões de produção.

4.3.1 Sensibilidade aplicada ao MPS

A primeira forma de sensibilidade ocorre diretamente no Módulo 05 – Inputs do MPS, onde o usuário pode ajustar os seguintes parâmetros operacionais: política de lote, tamanho de lote, estoque inicial, taxa de produção, congelamento de horizonte, estoque de segurança, pedidos em carteira e *lead-time*. Embora a demanda utilizada pelo MPS seja fixa, pois deriva da previsão gerada na etapa anterior, as alterações nesses parâmetros permitem avaliar como diferentes configurações impactam no MPS.

Com possibilidade de sensibilidade nestes parâmetros, o usuário pode, por exemplo, testar cenários como aumento do custo de *setup*, redução da capacidade produtiva, baixo estoque inicial ou eventos de negócio qualquer, observando como essas condições afetam o momento de liberação das ordens e o equilíbrio entre estoque e atendimento da demanda. Assim, o módulo demonstra sua utilidade para analisar *trade-offs* clássicos do PCP e compreender como pequenas variações nos parâmetros gerenciais resultam em ajustes no plano mestre final.

Cenário 1: Aumento do tamanho de lote (Q)

Este cenário avalia como o MPS reage a uma mudança estrutural na política de produção, especificamente ao aumento do tamanho do lote fixo. Trata-se de uma situação comum em ambientes industriais, onde a empresa opta por produzir lotes maiores para reduzir a frequência de setups, aproveitar ganhos de escala ou simplificar a programação da fábrica. Para representar esse contexto, o tamanho do lote foi ampliado de 500 (cenário base) para 800 unidades, mantendo constantes todos os demais parâmetros operacionais. Essa alteração permite observar o impacto direto no comportamento das ordens planejadas, no nível de estoque ao longo do horizonte e na estabilidade do plano, evidenciando como a política de lotes influencia a responsividade e a dinâmica do MPS.

MPS — Visualização Mensal

	Set/25	Out/25	Nov/25	Dez/25	Jan/26	Fev/26
Previsto	87	370	287	375	150	133
Em carteira	120	80	150	90	100	140
Estoque Proj.	63	493	206	631	481	348
Qtde. MPS	0	800	0	800	0	0
Início MPS	800	0	800	0	0	0
ATP(cum)	0	480	480	950	950	950

Figura 34: MPS - Cenário 1

Fonte: Os autores (2025)

Observa-se que o MPS recalcula automaticamente as ordens planejadas, ajustando sua distribuição ao longo do horizonte de forma coerente com a nova configuração estabelecida. Esse comportamento é evidenciado pelas mudanças nas linhas “Qtde. MPS”, que passa a receber um lote fixo maior, impactando em diversas outras linhas do MPS.

Com o aumento do lote, o plano passa a apresentar ordens menos frequentes e de maior volume, o que resulta em variações mais acentuadas no estoque projetado. O MPS também altera o momento em que as ordens são liberadas, concentrando a reposição em períodos específicos, o que é imediatamente visível na diferença entre as duas simulações. Da mesma forma, o ATP acumulado reage a essa nova configuração, passando a indicar maior disponibilidade no início do horizonte após a emissão de um lote mais volumoso.

Cenário 2: Mudança de política de lote (Fixo para Lote-a-lote)

Este cenário avalia o impacto da alteração da política de lote utilizada pelo MPS, substituindo a abordagem de lotes fixos por uma política de lote por lote. Essa mudança é comum quando a empresa busca maior alinhamento entre produção e demanda, redução do estoque médio ou maior flexibilidade diante de oscilações previstas no horizonte. Para simular essa condição, o tamanho do lote fixo foi desativado e as ordens passaram a ser programadas exatamente conforme a necessidade líquida de cada período. A análise desse cenário permite observar como o MPS se torna mais responsivo e reduz estoques, ao custo de maior frequência de ordens e menor estabilidade do plano.

MPS — Visualização Mensal

	Set/25	Out/25	Nov/25	Dez/25	Jan/26	Fev/26
Previsto	87	370	287	375	150	133
Em carteira	120	80	150	90	100	140
Estoque Proj.	63	92	71	93	37	33
Qtde. MPS	0	399	266	397	94	129
Início MPS	399	266	397	94	129	0
ATP(cum)	0	169	195	402	402	402

Figura 35: MPS - Cenário 2

Fonte: Os autores (2025)

A alteração da política de lote gera mudanças diretas na estrutura do MPS, especialmente nas linhas que definem as ordens liberadas e o comportamento do estoque. As quantidades planejadas passam a acompanhar de forma mais próxima as necessidades de cada período, resultando em reposições mais frequentes e distribuídas ao longo do horizonte, o que se reflete nas linhas “Qtde. MPS” e “Início MPS”. Em consequência, o “Estoque Projetado” apresenta oscilações menores entre os meses, com valores mais alinhados ao consumo previsto, reduzindo variações abruptas observadas no cenário base.

No ATP acumulado, observa-se um comportamento mais gradual, já que as disponibilidades passam a ser liberadas em volumes menores, porém de maneira contínua ao longo do horizonte. O conjunto dessas alterações evidencia a capacidade da ferramenta de ajustar imediatamente o plano mestre quando submetida a uma política de lote diferente, refletindo essa mudança tanto nas quantidades produzidas quanto no comportamento dos estoques e da disponibilidade futura.

Cenário 3: Venda de pedido extraordinário (Pedidos em carteira)

Este cenário simula a entrada de um pedido firme de grande porte. Para representar uma situação de alta pressão sobre o planejamento, foi inserido um pedido firme extraordinário de 1.800 unidades no mês de outubro de 2025, significativamente superior à demanda regular deste período. Esse tipo de ocorrência é bastante frequente em empresas que atendem órgãos governamentais ou instituições de ensino, em que pedidos concentrados podem demandar ajustes expressivos na programação da produção. Ao incorporar esse mega pedido no horizonte, vamos ver o impacto dentro do MPS. O objetivo deste cenário é evidenciar como demandas atípicas e concentradas impactam de forma direta o equilíbrio entre capacidade, estoque e

programação, demonstrando o papel do MPS para administração da produção nesse tipo de situação.

MPS — Visualização Mensal

	Set/25	Out/25	Nov/25	Dez/25	Jan/26	Fev/26
Previsto	87	370	287	375	150	133
Em carteira	120	1800	150	90	100	140
Estoque Proj.	63	193	406	531	381	248
Qtde. MPS	0	500	500	500	0	0
Início MPS	500	500	500	0	0	0
ATP(cum)	0	0	260	430	430	430

Figura 36: MPS - Cenário 3

Fonte: Os autores (2025)

A inclusão de um pedido firme de grande porte altera de forma imediata a estrutura do MPS, especialmente na linha “Em carteira”, onde se observa a concentração da demanda no mês de outubro. A presença desse volume adicional leva o sistema a recalcular o estoque projetado, que passa a apresentar valores significativamente superiores após o atendimento desse pedido. Esse ajuste também se reflete nas linhas “Qtde. MPS” e “Início MPS”, que mantêm a programação de lotes conforme a política vigente, mas agora em um contexto de maior necessidade acumulada no início do horizonte.

Como consequência, o ATP acumulado passa a refletir um comportamento diferenciado, indicando disponibilidade futura somente após o processamento do pedido concentrado. Os valores se tornam progressivamente positivos nos meses seguintes, acompanhando o escoamento do estoque projetado e a liberação das quantidades planejadas. Esse conjunto de alterações evidencia como o artefato ajusta automaticamente o plano mestre quando exposto a uma demanda concentrada, permitindo ao usuário visualizar de maneira clara os efeitos de um evento de grande impacto sobre o comportamento das ordens, do estoque e da disponibilidade para promessas.


4.3.2 Sensibilidade aplicada aos custos do MPS

Além das simulações estruturais realizadas diretamente sobre o MPS, o artefato também permite ao usuário explorar cenários de sensibilidade voltados aos custos associados ao planejamento da produção. Diferentemente da etapa anterior, na qual alterações impactam a programação das ordens, nesta seção os parâmetros econômicos influenciam apenas a

composição dos custos totais de manter, *setup* e custo total observado, sem alterar o MPS já gerado. Assim, é possível avaliar como mudanças nos custos de *setup*, de manutenção de estoque, no preço unitário ou no custo de falta modificam o comportamento econômico do plano, permitindo compreender *trade-offs* clássicos entre estoque, capacidade, tamanho de lote e risco de ruptura. Essa análise é essencial para demonstrar como o artefato pode apoiar decisões estratégicas de gestão de custos, auxiliando o usuário a identificar configurações mais econômicas em diferentes cenários operacionais.

Cenário 4: Aumento no custo de *setup* (A)

Este cenário simula uma situação comum no ambiente produtivo: o aumento inesperado do custo de preparação das máquinas, seja por reajuste de insumos utilizados no *setup* (como tinta, gabaritos de solda ou abrasivos), seja por maior tempo de ajuste decorrente de manutenção, ou outros fatores. Para representar esse contexto, o custo fixo de *setup* foi elevado de R\$ 300,00 (cenário base) para R\$ 600,00 por lote, mantendo todos os demais parâmetros constantes. O objetivo é avaliar como o MPS responde a um aumento significativo no custo de mudança de lote e de preparação da produção, evidenciando o impacto dessa variação no comportamento das ordens planejadas e na estratégia operacional mudança de dimensionamento de lotes.



Comparação rápida com o MPS atual (Gerado na página 06)

MPS Simulado — Total (R\$)

5.080,43

MPS atual — Total (R\$)

4.240,16

Diferença (sim - atual) ☺

840,27

Figura 37: Custos MPS - Cenário 4


Fonte: Os autores (2025)

Ao recalcular a curva de sensibilidade para diferentes tamanhos de lote, o sistema atualiza os componentes de custo e evidencia que o aumento no valor de *setup* provoca mudanças perceptíveis na composição das curvas. Isso pode ser observado no comportamento da linha “*Setup* (mês)”, que passa a assumir valores mais elevados ao longo de toda a faixa de Q, impactando também a curva do custo total mensal.

Na comparação numérica exibida abaixo do gráfico, a ferramenta apresenta de forma direta o efeito da alteração: o MPS Simulado passa a registrar um total de R\$ 5.080,43, enquanto o MPS atual permanece em R\$ 6.180,00, gerando uma diferença de –R\$ 1.099,57 entre os cenários. Esse contraste permite visualizar claramente a sensibilidade do modelo ao parâmetro ajustado, destacando como a mudança em A repercute nos valores finais calculados para o cenário simulado.

Cenário 5: Redução da capacidade produtiva (p)

A redução da capacidade produtiva representa uma situação comum na rotina industrial, geralmente associada a paradas de manutenção, indisponibilidade de operadores ou falhas em equipamentos críticos. A diminuição da taxa de produção exerce impacto direto sobre o custo total do sistema. Com a produção mais lenta, a empresa tende a manter níveis mais elevados de estoque de segurança por mais tempo, aumentando o custo de manter unidades armazenadas. Além disso, atrasos acumulados podem gerar custos indiretos associados ao risco de falta ou à postergação de reposições, mesmo que o plano mestre permaneça estruturalmente inalterado. Para simular essa situação, reduziu-se a taxa de produção de 2.500 unidades/mês para 1.500 unidades/mês, mantendo todos os demais parâmetros constantes. O objetivo é demonstrar como restrições de capacidade influenciam a dinâmica econômica do planejamento.



Comparação rápida com o MPS atual (Gerado na página 06)

MPS Simulado – Total (R\$)

4.006,75

MPS atual – Total (R\$)

4.240,16

Diferença (sim - atual) ⓘ

-233,41

Figura 38: Custos MPS - Cenário 5

Fonte: Os autores (2025)

A redução da capacidade altera diretamente o comportamento das curvas apresentadas, e isso pode ser visto especialmente no formato das linhas do gráfico: a curva de *setup* se reduz de forma mais intensa para valores de Q maiores, enquanto a curva de *manter* apresenta inclinações distintas em relação ao cenário base. O efeito consolidado é refletido na linha de custo total mensal, que assume um novo padrão ao longo da faixa de tamanhos de lote.

Na comparação numérica exibida na seção inferior, essa alteração aparece de forma explícita. O MPS Simulado registra um total de R\$ 4.847,02, enquanto o MPS atual permanece em R\$ 6.180,00, resultando em uma diferença de –R\$ 1.332,98. Essa visualização direta permite identificar como a mudança de capacidade impacta o custo total estimado pelo modelo, reforçando a sensibilidade da ferramenta ao ajuste do parâmetro p e evidenciando sua capacidade de recalcular automaticamente os valores econômicos com base em novas condições operacionais.

4.3.3 Sensibilidade aplicada ao ATP Acumulado

A análise de sensibilidade aplicada ao ATP acumulado tem como objetivo avaliar a capacidade da empresa de aceitar novos pedidos sem comprometer compromissos já firmados. Diferentemente da etapa anterior, o ATP não é recalculado a partir de mudanças nos parâmetros produtivos; ele permanece vinculado ao MPS já gerado. Assim, a sensibilidade ocorre exclusivamente pela inserção de novos pedidos simulados pelo usuário, permitindo analisar até que ponto a disponibilidade futura suporta demandas adicionais. Essa funcionalidade é especialmente útil para decisões comerciais, uma vez que possibilita visualizar, de forma direta, se a empresa possui capacidade de atendimento ao longo do horizonte ou se novas solicitações provocariam atrasos, rupturas ou necessidade de replanejamento.

Cenário 6: Pedido extraordinário

Este cenário simula a chegada de um novo pedido de médio porte, não previsto originalmente, proveniente de um cliente corporativo ou instituição que necessita de atendimento rápido. Para representar esse contexto, foi inserido um pedido adicional de 300 unidades. Esse tipo de solicitação é comum em empresas de móveis escolares que atendem empresas privadas e instituições de ensino que, por vezes, demandam reposição de mobiliário de forma emergencial. Ao simular esse pedido sobre a curva de ATP acumulado, o usuário consegue identificar se existe disponibilidade suficiente para absorver essa nova demanda sem comprometer entregas previamente comprometidas.




Figura 39: ATP - Cenário 7

Fonte: Os autores (2025)

A ferramenta compara o ATP acumulado de cada período com a demanda extra hipotética, indicando de forma visual e tabular os meses em que essa solicitação poderia ser atendida. Na simulação apresentada, os meses de novembro, dezembro, janeiro e fevereiro apresentam disponibilidade suficiente, enquanto os períodos iniciais do horizonte não possuem margem para absorver a demanda adicional.

Dessa forma, o cenário demonstra a sensibilidade do módulo de ATP ao testar a inclusão de novas demandas, permitindo ao usuário avaliar rapidamente a viabilidade de atender pedidos emergenciais sem comprometer os compromissos já firmados no MPS.

4.4 Avaliação do protótipo com especialistas do caso

A avaliação do artefato desenvolvido teve como objetivo verificar se a solução atendia às duas necessidades centrais identificadas pela empresa: prever a demanda individual de um produto específico e estimar a demanda agregada de múltiplos itens simultaneamente. Para isso, foram conduzidos dois testes distintos, previamente descritos na seção metodológica, e seus resultados foram apresentados aos especialistas da organização. Essa etapa buscou não apenas confirmar a capacidade técnica do artefato em gerar previsões consistentes, mas também avaliar sua adequação prática ao cotidiano da área de PCP, considerando o uso real que a empresa faria das informações geradas.

Os especialistas avaliaram positivamente o artefato, destacando sua utilidade prática e a aderência às necessidades da área de produção. Ambos consideraram a solução “muito interessante” e ressaltaram que o trabalho estava completo e bem estruturado, especialmente pela integração entre a previsão de demanda e as análises exploratórias apresentadas. Um dos

pontos reforçados foi a boa capacidade do artefato de oferecer uma visão holística da produção ao permitir comparar previsão e resultados efetivos, favorecendo o planejamento por período. Os avaliadores também demonstraram interesse em ampliar o uso da ferramenta, questionando a possibilidade de aplicá-la a outros produtos além dos testados e sugerindo sua extensão para etapas específicas do processo, como a serralheria. Essas observações reforçaram a boa aderência do artefato e seu potencial de expansão para apoiar um planejamento mais detalhado e segmentado dentro do PCP.

5 CONCLUSÕES

Ao longo deste trabalho, as questões de pesquisa foram endereçadas por meio da revisão da literatura e da aplicação prática do artefato desenvolvido. A partir dos problemas identificados — previsões imprecisas, decisões empíricas e baixa integração entre demanda e PCP — investigamos fundamentos teóricos capazes de orientar soluções mais robustas para a manufatura. A literatura destacou a relevância dos modelos de séries temporais para identificar padrões estruturais da demanda e fortalecer o processo de previsão, permitindo sua utilização dentro do MPS e das rotinas de planejamento. Com base nessas evidências, optou-se por integrar tais modelos às ferramentas de PCP no artefato computacional, possibilitando um planejamento mais organizado, previsões mais consistentes e maior estabilidade operacional, especialmente no balanceamento da produção e na redução das instabilidades observadas no sistema atual.

No estudo de caso realizado na empresa moveleira, demonstrou-se que o artefato computacional desenvolvido é capaz de aplicar, integrar e validar previsões de demanda dentro das principais ferramentas de PCP. A solução permitiu testar múltiplos modelos de séries temporais, selecionar automaticamente aquele com melhor desempenho e incorporar os resultados diretamente ao MPS, fornecendo ao gestor uma visão estruturada da demanda futura. Essa integração possibilitou reduzir a dependência de tomadas de decisão empíricas, torná-las mais consistentes e apoiar o balanceamento da capacidade produtiva. A validação conduzida junto aos profissionais de tecnologia e logística da empresa evidenciou que o artefato contribui de forma prática para aumentar a estabilidade do planejamento, reduzir incertezas operacionais e apoiar decisões mais fundamentadas, reforçando sua aplicabilidade e relevância no dia a dia do PCP.

As implicações teóricas e práticas deste trabalho evidenciam a relevância da integração entre previsão de demanda e PCP como solução estruturante para reduzir ineficiências operacionais em ambientes de manufatura. Do ponto de vista teórico, o estudo reforça achados da literatura ao demonstrar, na prática, que modelos de séries temporais são capazes de capturar padrões estruturais da demanda e oferecer previsões mais consistentes para subsidiar decisões produtivas, validando autores que defendem a importância de métodos quantitativos em contextos de alta variabilidade. Já em termos práticos, o artefato desenvolvido mostrou-se aplicável ao cotidiano da empresa moveleira ao padronizar o processo de previsão, automatizar a seleção de modelos, integrar resultados ao MPS e oferecer maior visibilidade ao

planejamento. Essa abordagem reduziu a dependência de julgamentos empíricos, aumentou a estabilidade do sequenciamento e contribuiu para decisões mais fundamentadas, demonstrando o potencial de soluções computacionais para fortalecer rotinas de PCP e apoiar gestores na organização e no balanceamento da produção.

Apesar dos resultados positivos, o estudo apresenta limitações importantes relacionadas tanto ao artefato quanto ao escopo do planejamento analisado. No módulo de previsão, o usuário não possui liberdade para ajustar manualmente os hiperparâmetros, que permanecem restritos à configuração pré-definida do sistema, o que reduz a flexibilidade em situações que demandem calibração fina ou conhecimento técnico avançado. No módulo de PCP, especificamente na construção do MPS, o artefato também impõe restrições: o planejamento é realizado exclusivamente em periodicidade mensal, não permitindo desdobramentos semanais ou diários, e a escolha do tamanho de lote limita-se às políticas de lote fixo ou lote a lote, restringindo a exploração de outras regras comuns em ambientes produtivos. Tais limitações não comprometem a utilidade do artefato, mas indicam oportunidades claras de evolução e maior aderência às práticas reais de manufatura.

Como trabalhos futuros, identificam-se diversas oportunidades de aprimoramento e ampliação do artefato, visando aumentar sua aderência às práticas industriais e sua robustez analítica. Uma das principais evoluções consiste na construção de uma árvore do produto, permitindo que o artefato avance para níveis mais detalhados de planejamento e possibilite sua integração ao *Material Requirements Planning* (MRP), ampliando o escopo para o cálculo das necessidades de materiais e sincronização entre demanda, produção e suprimentos. Além disso, a inclusão de um conjunto mais amplo de modelos de previsão, com maior flexibilidade na escolha e customização de hiperparâmetros, permitiria abarcar comportamentos mais diversos de demanda e oferecer previsões ainda mais precisas.

Em resumo, o trabalho mostrou que integrar previsões de demanda ao PCP melhora a estabilidade do planejamento e reduz decisões empíricas, especialmente quando apoiado por modelos de séries temporais. Apesar das limitações do artefato — como ajustes restritos de hiperparâmetros, poucas políticas de lote e planejamento apenas mensal — os resultados indicam sua utilidade prática e abrem espaço para evoluções, como integrar uma árvore do produto, ampliar modelos de previsão e conectar o sistema ao MRP.

6 BIBLIOGRAFIA

- ALDEGHERI, S. Investigation on the Influence of Remanufacturing on Production Planning and Control – A Systematic Literature Review. University of Hannover, 2024.
- ALI, S.; SINGH, A.; SOHAL, A. S. Data Analytics in Supply Chain Management: A State-of-the-Art Literature Review. *Operations and Supply Chain Management*, v. 17, n. 1, 2024.
- ASHLEY, R. On the Origins of Conditional Heteroscedasticity in Time Series. *Economics Bulletin*, v. 32, n. 4, 2012.
- BALLÔU, R. H. Gerenciamento da Cadeia de Suprimentos: planejamento, organização e logística empresarial. 5. ed. Porto Alegre: Bookman, 2006.
- BANDYOPADHYAY, S. Production and Operations Analysis: Traditional, Latest, and Smart Views. Boca Raton: CRC Press, 2019.
- BERGSTRA, J.; BENGIO, Y. Random Search for Hyper-Parameter Optimization. *JMLR*, v. 13, 2012.
- BOX, G. E. P.; COX, D. R. An Analysis of Transformations. *JRSS-B*, v. 26, 1964.
- CHAPMAN, S. N. The Fundamentals of Production Planning and Control. New Jersey: Pearson/Prentice Hall, 2006.
- CORRÊA, H. L.; CORRÊA, C. A. Administração de Produção e Operações: manufatura e serviços – uma abordagem estratégica. 2. ed. São Paulo: Atlas, 2008.
- COSTA NETO, P. L. O. Estatística. 2. ed. São Paulo: Edgard Blücher, 2002.
- DEL GALLO, I. et al. Artificial Intelligence to Solve Production Scheduling Problems. *Applied Sciences*, 2023.
- DIAS, M. A. P. Administração de Materiais: uma abordagem logística. 6. ed. São Paulo: Atlas, 2015.
- DICKEY, D. A.; FULLER, W. A. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *JASA*, v. 74, 1979.
- DOUAIOUI, K.; OUCHEIKH, R.; BENMOUSSA, O.; MABROUKI, C. Machine-Learning and Deep-Learning Models for Demand Forecasting in Supply Chain Management: A Critical Review. *Applied System Innovation*, v. 7, n. 5, 2024.

- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, v. 50, 1982.
- FACCHINI, E.; SILVA, J. R.; LEITE, V. M. Curva ABC e estoque de segurança como solução para redução de estoque. *South American Development Society Journal*, v. 5, n. 13, 2019.
- FATIMA, S. S. W.; RAHIMI, A. A Review of Time-Series Forecasting Algorithms for Industrial Manufacturing Systems. *Machines*, v. 12, 2024.
- GOLTSOS, E. Inventory–Forecasting: Mind the Gap. *European Journal of Operational Research*, v. 297, 2022.
- GREENE, W. H. *Econometric Analysis*. 8. ed. New York: Pearson Education, 2018.
- GUNASEKARAN, A.; NGAI, E. W. Research and opportunities in supply chain modeling: A review. *International Journal of Industrial Engineering*, 2012.
- GUO, L.; RIBEIRO, R.; SGARBOSSA, F. Using machine learning for production scheduling problems in the supply chain: A review. *Computers & Industrial Engineering*, v. 194, 2025.
- GUPTA, N.; MATHUR, T.; SADHUKHAN, R. A smart DDMRP model using machine learning techniques. *International Journal of Value Chain Management*, 2023.
- HOLSE, J.; HENNINGSEN, K.; NIELSEN, T. Forecasting and Inventory Planning: An Empirical Investigation of Classical and Machine Learning Approaches for Svanehøj's Future Software Consolidation. *Applied Sciences*, v. 13, 2023.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. Melbourne: OTexts, 2024.
- HYNDMAN, R.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 3. ed., 2021.
- JACOBS, F. R.; CHASE, R. B.; AQUILANO, N. J. *Manufacturing Planning and Control for Supply Chain Management: The CPIM Reference*. 2. ed. New York: McGraw-Hill Education, 2018.
- KAUR, H.; SINGH, S. P. Artificial intelligence in supply chain management: Theory and applications. *International Journal of Production Research*, 2010.

- KAYA, E.; SAHIN, Y.; DEMIREL, N. C. Intermittent Demand Forecasting: A Guideline for Method Selection. *Sigma Journal of Engineering and Natural Sciences*, v. 38, 2020.
- KHEDR, A. M. et al. Enhancing Supply Chain Management with Deep Learning: Inventory Control, Demand Forecasting and Order Management. *Procedia Computer Science*, v. 240, 2024.
- KIM, K.; LEE, Y.; TSENG, M. Deploying hybrid modelling to support the development of a digital twin for supply chain master planning under disruptions. *International Journal of Production Research*, 2023.
- KRAJEWSKI, L.; RITZMAN, L.; MALHOTRA, M. *Administração da Produção e Operações*. 11. ed. São Paulo: Prentice Hall, 2017.
- KRAJEWSKI, L. J.; RITZMAN, L. P. *Operations Management: Processes and Value Chains*. 8. ed. New Jersey: Prentice Hall, 2004.
- KRAJEWSKI, L. J.; RITZMAN, L. P. *Operations Management: Strategy and Analysis*. New Jersey: Prentice Hall, 2002.
- KUMAR, R.; SARKAR, A. Framework for predictive sales and demand planning in customer-oriented manufacturing systems using data enrichment and machine learning. *Procedia CIRP*, 2023.
- KWIATKOWSKI, D. et al. Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root. *Journal of Econometrics*, v. 54, 1992.
- LI, X.; CHEN, Y.; WANG, S. Demand Forecasting Model for Airline Flights Based on Historical Passenger Flow Data. *Applied Sciences*, v. 14, n. 23, 2024.
- LIMA, F. R. et al. Demand Forecasting, Production Planning, and Control: A Systematic Literature Review. *Gestão & Produção*, v. 28, 2021.
- LIU, W.; YIN, S.; ZHANG, H. A digital twin-enabled digital spare parts supply chain. *International Journal of Production Research*, 2024.
- LÜTKEPOHL, H.; XU, F. The Role of the Log Transformation in Forecasting Economic Variables. *CESifo Working Paper*, n. 2591, 2009.

MA, Y.; HU, S.; VAN DER AALST, W. Reinforcement learning for logistics and supply chain management: Methodologies, state of the art, and future opportunities. *Transportation Research Part E*, v. 166, 2022.

MAIER, P. E. A Systematic Literature Review of Machine Learning Methods for Production Planning and Control Tasks. *Procedia CIRP*, v. 107, 2022.

MEYER, R.; BABAI, M. Z.; SYNTETOS, A. A data-driven methodology for the periodic review of spare parts supply chain configurations. *International Journal of Production Research*, 2023.

MÜLLER, V.; KÖNIG, A. Efficiency Analysis of Hybrid Forecasting Models Supporting Manufacturing Companies in Production Planning, Maintenance and Quality Management. *Lecture Notes in Computer Science*, 2021.

NAHMIAS, S.; OLSEN, T. L. *Production and Operations Analysis*. 7. ed. Illinois: Waveland Press, 2015.

ORTEGA, A.; KADAI, F. C.; IVANOV, D. Incorporating supply and production digital twins to mitigate demand disruptions in multi-echelon networks. *International Journal of Production Economics*, v. 266, 2024.

PINEDO, M.; WATSON, H. A framework for semiconductor industry supply chain planning: Perspectives of intelligent enterprise. *International Journal of Production Research*, 2010.

POLO-TRIANA, S.; GUTIÉRREZ, J.; LEÓN-BECERRA, C. Integration of Machine Learning in the Supply Chain for Decision Making: A Systematic Literature Review. *Journal of Industrial Engineering and Management*, 2024.

POZO, H. *Administração de Recursos Materiais e Patrimoniais*. 6. ed. São Paulo: Atlas, 2010.

RAMÍREZ-GALLEGO, S. et al. A survey on data preprocessing for data stream mining. *Neurocomputing*, v. 239, 2017.

RANA, M.; SHARMA, R.; JANG, S. Analytics Applications in Fashion Supply Chain Management – A Review of Literature and Practice. *IEEE Transactions on Engineering Management*, 2021.

RANJAN, R.; RAO, C. Application of nature inspired algorithms for multi-objective inventory control scenarios. *International Journal of Industrial and Systems Engineering*, 2020.

SALAMA, A.; DWYER, N.; BABAI, Z. Machine Learning for Master Production Scheduling: Combining probabilistic forecasting with stochastic optimisation. *Expert Systems with Applications*, v. 235, 2025.

SANTA ANA, M. F. A Curva ABC na Gestão de Estoque. *Brazilian Journal of Development*, v. 7, n. 5, 2021.

SATTAR, M. U. et al. Enhancing Supply Chain Management: A Comparative Study of Machine Learning Techniques for Demand Forecasting. *Sustainability*, v. 17, 2025.

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality. *Biometrika*, v. 52, 1965.

SINGH, R.; PRASAD, D. An improved production planning method for process industries. *International Journal of Production Research*, 2013.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. *Administração da Produção*. 3. ed. São Paulo: Atlas, 2009.

THADEWALD, T.; BÜNING, H. Jarque–Bera test and its competitors: A power comparison. *Diskussionsbeiträge*, Freie Universität Berlin, 2004.

TUBINO, D. F. *Planejamento e Controle da Produção: teoria e prática*. 2. ed. São Paulo: Atlas, 2009.

VENKATESH, S.; RAJESH, R. Leveraging synthetic data to tackle machine learning challenges in supply chains: challenges, methods, applications, and research opportunities. *International Journal of Production Research*, 2024.

VOLLMANN, T. E.; BERRY, W. L.; WHYBARK, D. C. *Manufacturing Planning and Control Systems for Supply Chain Management*. 5. ed. New York: McGraw-Hill, 2006.

WANG, W.; JAFARI, M.; AKBARI, A. H. Efficient Algorithms for Dynamic Cellular Manufacturing Systems by Considering Blockchain-Enabled (Case Study: Stone Paper Factory). *Journal of Advanced Manufacturing Systems*, v. 24, n. 4, 2025.

XANTHOPOULOS, P.; VLACHOS, I. P. On the use of machine learning in supply chain management: a systematic review. *IMA Journal of Management Mathematics*, 2025.

ZHOU, T.; YANG, X.; ZHANG, C. Multi-echelon inventory optimization of waste electrical and electronic equipment closed-loop supply chain based on reinforcement learning under carbon tax policy. *Engineering Applications of Artificial Intelligence*, v. 136, 2025.

7 APÊNDICE

7.1 Apêndice A – Código *Streamlit*

Para garantir transparência, reprodutibilidade e acesso público ao artefato desenvolvido neste trabalho, o sistema foi depositado na plataforma Zenodo, um repositório internacional voltado ao arquivamento e disseminação de produções científicas. O link abaixo direciona ao registro oficial do projeto, contendo os códigos, arquivos e documentação necessários para execução e consulta do artefato. Este repositório assegura a preservação digital do material e permite que futuros pesquisadores ou profissionais utilizem e expandam a solução proposta.

DOI gerado no Zenodo: <https://doi.org/10.5281/zenodo.17675743>

7.1 Apêndice B – Experimentos

Link para acesso aos experimentos gerados pelo artefato:
[experimentos_unificado_artefato.xlsx](#)

Nele, você encontrará todos os resultados produzidos durante a etapa de previsão, incluindo as variações de modelos, métricas de desempenho e arquivos exportados automaticamente pelo sistema.