

Avaliação de Modelos de Previsão de Demanda para Insumo Químico Perecível na Cadeia Automotiva

Evaluation of Demand Forecasting Models for Perishable Chemical Inputs in the Automotive Supply Chain

Brenda Gabrielle Nogueira

Fatec, São José dos Campos, São Paulo
E-mail: brenda.nogueira@fatec.sp.gov.br

Christopher Alexander Silva Leão

Fatec, São José dos Campos, São Paulo
E-mail: christopher.leao@fatec.sp.gov.br

Daniel Miguel da Silva

Fatec, São José dos Campos, São Paulo
E-mail: daniel.silva396@fatec.sp.gov.br

Helloísa Chinaide de Deus Reis

Fatec, São José dos Campos, São Paulo
E-mail: helloisa.reis@fatec.sp.gov.br

Reinaldo Viveiros Carraro

Fatec, São José dos Campos, São Paulo
E-mail: rvcarraro@fatec.sp.gov.br

RESUMO

A competitividade no setor automotivo impõe desafios logísticos críticos, especialmente na gestão de insumos perecíveis com longo *lead time* de fornecimento. Este trabalho apresenta um diagnóstico do desempenho dos métodos de previsão de demanda aplicados ao controle de estoque de um produto químico (*Primer*) com validade restrita, utilizado por uma empresa vidraceira fabricante de para-brisas. O estudo de caso, de natureza aplicada e abordagem exploratória, avaliou o método de média simples atualmente utilizado pela empresa e propôs a aplicação de modelos estatísticos mais acurados. Os resultados indicam que a baixa acurácia da previsão atual compromete a gestão de estoque, expondo a empresa a riscos de obsolescência e ruptura. A metodologia proposta visa identificar padrões de sazonalidade e comportamento da demanda, oferecendo subsídios para um planejamento logístico mais eficiente e sustentável, minimizando os impactos das incertezas do mercado e otimizando a eficiência da cadeia de suprimentos.

Palavras-chave: Previsão de Demanda; Gestão de Estoques; Produto Perecível; Logística Automotiva.

ABSTRACT

The competitiveness of the automotive sector imposes critical logistical challenges, particularly in managing perishable inputs with long supply lead times. This study presents a diagnostic analysis of the performance of demand forecasting methods applied to inventory control of a chemical product (Primer) with limited shelf life, used by a glass manufacturing company that produces windshields. The case study, applied in nature and exploratory in approach, evaluated the simple average method currently used by the company and proposed the adoption of more accurate statistical models. The results indicate that the low accuracy of the current forecasting method compromises inventory management, exposing the company to risks of obsolescence and stockouts. The proposed methodology aims to identify patterns of seasonality and demand behavior, providing support for more efficient and sustainable logistical planning, minimizing the impacts of market uncertainties and optimizing supply chain efficiency.

Keywords: Demand Forecasting; Inventory Management; Perishable Product; Automotive Logistics.

1 INTRODUÇÃO

A competitividade no setor automotivo exige que todos os elos da cadeia de suprimentos operem com alta eficiência. Segundo Ballou (2006), a logística é responsável por disponibilizar produtos e serviços no local e tempo corretos, ao menor custo possível, o que se torna um diferencial estratégico em mercados competitivos. Os desafios logísticos tornam-se ainda mais críticos, especialmente quando o fornecimento de insumos depende de rotas internacionais e produtos químicos com prazo de validade restrita, exigindo alto nível de controle, planejamento e agilidade.

É necessário analisar e propor melhorias no processo de abastecimento logístico de um produto químico perecível, utilizado por uma empresa vidraceira fabricante de para-brisas, cuja produção está inserida diretamente na cadeia automotiva. O *Primer* é um insumo fundamental para a fixação do vidro na carroceria dos veículos, e sua integridade impacta diretamente a segurança e a qualidade final do produto. Conforme Bowersox, Closs e Cooper (2014), a coordenação eficiente dos fluxos de materiais é essencial para manter a continuidade das operações e evitar rupturas na cadeia produtiva.

O produto em questão possui uma vida útil limitada de aproximadamente seis meses, sendo que cerca de quatro meses são utilizados apenas no processo de transporte e trâmites aduaneiros, o que representa um risco ao aproveitamento da carga. O trajeto logístico atual envolve a saída do produto do Japão via modal marítimo, seguido por uma etapa de transbordo e transporte aéreo a partir dos Estados Unidos até o Brasil.

O *lead time* dos fornecedores confronta com a agilidade exigida pelo cliente final, que depende de uma cadeia produtiva contínua e com baixa tolerância a atrasos. Isso exige a adoção de soluções que assegurem o abastecimento da fábrica sem a geração de estoques excessivos, os quais podem se deteriorar devido à perecibilidade do material. Segundo Slack, Chambers e Johnston (2009), o equilíbrio entre estoque, demanda e capacidade produtiva é um dos principais desafios da gestão operacional. Assim, o planejamento de demanda se torna uma ferramenta indispensável, pois está diretamente ligada ao controle de estoque, à gestão da mão de obra, às compras, à capacidade produtiva e às vendas.

A empresa vidraceira estudada utiliza médias simples para calcular a necessidade de compra. No entanto, esse método muitas vezes não contempla variações sazonais, oscilações de mercado e imprevistos operacionais, o que compromete a acuracidade das projeções. Ballou (2006) ressalta que o uso de modelos estatísticos mais avançados e o monitoramento contínuo dos dados permitem maior precisão nas previsões e melhor desempenho logístico.

O objetivo geral do trabalho é de analisar a operação atual, identificar pontos críticos e propor melhorias com base em boas práticas logísticas e previsão de demanda. A abordagem teórico-prática deste trabalho busca construir um modelo mais eficiente, garantindo o abastecimento sem comprometer sua validade e a produção vidraceira.

A relevância desse estudo é demonstrar como a previsibilidade de demanda influencia a cadeia de suprimento de um material químico perecível em uma empresa do setor automotivo especializada na fabricação de para-brisas, buscando minimizar os impactos das incertezas do mercado e otimizar a eficiência logística.

Para alcançar os objetivos propostos, este trabalho foi estruturado como uma pesquisa aplicada, de natureza qualitativa e abordagem exploratória, utilizando o método de estudo de caso. A coleta de dados será realizada com base em documentos internos da empresa.

Ao final, espera-se apresentar propostas viáveis que possam ser aplicadas na empresa estudada, contribuindo para uma gestão de demanda mais previsível.

2 REFERENCIAL TEÓRICO

2.1. Efeito Chicote

Conforme apontado pelo autor Forrester (1961), O efeito chicote, ocorre quando há falhas na comunicação entre os agentes da cadeia de suprimentos diante de uma alteração na

demanda do consumidor final. Nessas situações, os fornecedores tendem a reagir de forma exagerada, ampliando os pedidos a cada etapa da cadeia. Cada elo busca se proteger, aumentando ou reduzindo suas encomendas além do necessário. Em cadeias mais extensas, esse fenômeno pode gerar impactos bastante negativos, já que as distorções se acumulam progressivamente do consumidor até o fornecedor. Isso pode causar sérios prejuízos às programações de produção.

Em outras palavras, segundo Zhang (2004), O efeito chicote ocorre quando uma expectativa de demanda ou oferta não se concretiza, devido a diferentes fatores, como a dificuldade em prever com precisão as necessidades do mercado. Essa discrepância provoca um impacto que se propaga ao longo de toda a cadeia de suprimentos, afetando diretamente os níveis de estoque e os volumes de pedidos entre as empresas envolvidas.

A demanda do cliente serve como ponto de partida para todo o processo operacional. Considerando que a cadeia de suprimentos é composta por múltiplos agentes, como fornecedores, fabricantes, atacadistas e varejistas, a informação precisa atravessar todos esses elos antes de alcançar o consumidor final. Essa estrutura evidencia a necessidade de fortalecer tanto os processos quanto a coordenação da informação, com o objetivo de mitigar as variabilidades decorrentes ao longo da cadeia. Mesmo uma leve alteração ou flutuação sazonal na demanda dos clientes pode desencadear o efeito dominó, conhecida como "bater o chicote", impactando diretamente os fornecedores.

Em uma tentativa de quantificar os danos decorrentes da propagação de erros na avaliação das incertezas da demanda, os autores Lee, Padmanabhan e Whang (1997) estimaram que, o efeito chicote pode resultar em um aumento de custo que varia na faixa de 12,5% a 25% ao longo da cadeia de suprimentos.

O Efeito Chicote é um desafio complexo de identificar, uma vez que envolve detalhes que passam despercebidos por muitas empresas. A prevenção desse efeito requer esforços para suavizar as flutuações na demanda. Além disso, manter uma comunicação clara e eficiente entre todos os agentes da cadeia de suprimentos é crucial, envolvendo o compartilhamento de informações sobre demanda, níveis de estoque e previsões de maneira integrada.

2.2. Demanda

A demanda representa a quantidade de bens ou serviços que os consumidores desejam adquirir em determinado período, a um dado preço. Dentro do contexto organizacional,

entender e prever a demanda são essenciais para alinhar os recursos produtivos, planejar estoques, coordenar compras e definir estratégias de atendimento ao mercado (MARTINS; LAUGENI, 2005).

Segundo Krajewski, Ritzman e Malhotra (2009, p. 437), "na origem da maioria das decisões de negócios está o desafio de prever a demanda do cliente. É uma tarefa difícil porque a demanda por serviços e bens pode variar muito". Essa variação pode ocorrer por fatores sazonais, tendências de consumo, condições econômicas, mudanças tecnológicas ou até eventos inesperados, como crises ou desastres naturais.

Além disso, a natureza da demanda pode ser classificada como dependente ou independente. A demanda independente é aquela que não está ligada à demanda de outros produtos (como os bens finais), enquanto a dependente está relacionada a outros itens, como componentes ou matérias-primas (SLACK et al., 2009). A correta identificação desse tipo de demanda influencia diretamente na escolha do modelo de gestão a ser adotado, como MRP (Material Requirements Planning), sistemas de produção puxada (pull) ou empurrada (push).

Em resumo, uma gestão eficiente da demanda não só garante o atendimento aos clientes com qualidade e pontualidade, como também oferece vantagens competitivas ao diminuir os custos operacionais, prevenir acúmulos de estoque e ampliar a eficiência no uso dos recursos internos.

2.3. Previsão de demanda

A demanda pode ser compreendida como a quantidade de produtos ou serviços necessários para atender às necessidades dos consumidores em determinado mercado, sendo influenciada por fatores como o tipo de produto, a localização geográfica e o tempo de atendimento. A correta estimativa e gestão dessa demanda são fundamentais para melhorar o nível de serviço ao cliente e para otimizar os processos logísticos e produtivos dentro das organizações. Empresas que utilizam dados históricos e técnicas de previsão conseguem planejar melhor suas operações, reduzindo estoques desnecessários e aumentando a eficiência operacional (BALLOU, 2007; ANZANELLO; FOGLIATTO, 2010; WERNER, 2004).

A consolidação desses dados proporciona uma orientação para o ambiente produtivo, servindo como justificativa para investimentos no aumento da capacidade, impactando toda a abrangência estratégica da organização (CASAGRANDE, 2010; LEMOS, 2006).

A previsão da demanda possibilita agir sobre estoques, número de funcionários, processos e operações problemáticas, além de gerenciar a relação com o cliente. Isso possibilita prever os insumos que serão necessários para a produção.

O comportamento da demanda em um período de tempo específico origina as séries temporais, que são categorizadas em regulares e irregulares. A demanda regular pode ser dividida em elementos como a demanda média (mantém uma demanda horizontal), sazonal (representa picos e valores que se repetem sempre nos mesmos períodos, ou seja, nas mesmas épocas do ano), tendencial (representa a movimentação em um período específico) e cíclica (representa variações aleatórias que podem se repetir em períodos de dia, mês, ano ou outros intervalos de tempo). Por outro lado, a demanda irregular, também referida como aleatória, se distingue pela irregularidade e intermitência dos dados (KRAJEWSKI, RITMAN, MALHOTRA, 2009; LEMOS, 2006).

2.4. Métodos de previsão de demanda

De acordo com Moreira (2011) e Corrêa (2012), os métodos de previsão podem ser classificados com base nos instrumentos e conceitos utilizados, sendo a partir dessa estrutura que se desenvolve o processo de previsão. Os principais métodos destacados pelos autores são:

- a) Qualitativos (ou baseados no julgamento): referem-se a métodos fundamentados principalmente no julgamento de pessoas que, direta ou indiretamente, estejam aptas a opinar sobre a demanda futura, como gerentes, vendedores, clientes, fornecedores, entre outros.
- b) Matemáticos (ou quantitativos): consistem em métodos que utilizam modelos matemáticos para estimar os valores previstos. Essa abordagem permite o controle do erro, mas exige a disponibilidade de informações quantitativas preliminares.

Segundo Corrêa (2012), os métodos qualitativos são mais complexos de serem avaliados, pois dependem da análise subjetiva de especialistas. Nesse contexto, Moreira (2011, p. 295) explica que “os métodos qualitativos são baseados no julgamento e na experiência de pessoas que possam, por suas próprias características e conhecimentos, emitir opiniões sobre eventos futuros de interesse”.

Por outro lado, os métodos quantitativos exigem dados históricos para possibilitar previsões, como destacam Krajewski, Ritzman e Malhotra (2009, p. 439): —Previsões com

métodos quantitativos são possíveis apenas quando existem dados históricos adequados, muitas vezes chamados arquivos históricos por vários softwares comerciais.

2.5 Métodos quantitativos

Os métodos quantitativos de previsão utilizam dados históricos como base para identificar padrões de comportamento ao longo do tempo. A partir dessas análises, é possível projetar esses padrões para o futuro, com o objetivo de estimar resultados de forma mais precisa. Como destaca Corrêa (2012), são os métodos de previsão baseados em séries de dados históricos nas quais se procura, através de análises, identificar padrões de comportamento para que estes sejam então projetados para o futuro.

2.5.1 Modelo de Média Móvel Simples

O modelo de média móvel simples utiliza a média de períodos anteriores para estimar a demanda futura. Segundo Martins e Laugeni (2005, p. 228), é necessário definir previamente a quantidade de períodos considerados para o cálculo da média. Krajewski, Ritzman e Malhotra (2009) apresentam a fórmula utilizada:

$$MMS = \frac{D1+D2+\dots+Dn}{n} \quad (4)$$

Onde:

D1, D2...Dn = demanda registradas em cada período

n = número de períodos considerados na média

O resultado é a previsão para o próximo período.

Martins e Laugeni (2005) destacam que, por serem baseadas em dados históricos, essas previsões assumem que o futuro será uma continuação do passado. Moreira (2011, p. 312) afirma que a média móvel simples é eficiente quando a demanda é estacionária, ou seja, quando oscila em torno de uma média constante, mas apresenta limitações em casos de sazonalidade.

2.5.2 Modelo de Média Móvel Ponderada (MMP)

Martins e Laugeni (2005, p. 228) explicam que o modelo de média móvel ponderada atribui pesos específicos aos dados históricos, de forma que a soma desses pesos seja igual a 1.

Assim como no modelo simples, considera-se n períodos passados, mas os valores recebem pesos diferentes.

De acordo com Moreira (2011, p. 312), esse modelo valoriza mais os períodos mais recentes. Krajewski, Ritzman e Malhotra (2009) explicam que o cálculo consiste em multiplicar cada valor da demanda pelo seu respectivo peso e somar os resultados.

Apesar disso, o modelo apresenta limitações semelhantes ao da média móvel simples: exige n períodos consecutivos de dados para o cálculo (KRAJEWSKI; RITZMAN; MALHOTRA, 2009, p. 446). A definição dos pesos pode ser um desafio, pois depende de informações internas da empresa e da importância atribuída a cada período, o que varia de organização para organização.

$$MMP = \frac{(D1 \times P1) + (D2 \times P2) + \dots + (Dn \times Pn)}{P1 + P2 + \dots + Pn} \quad (5)$$

Onde:

D = demanda em cada período

P = peso atribuído a cada período (maior peso para períodos mais recentes/0

N = número de períodos analisados

2.5.3 Modelo de Suavização Exponencial

Segundo Krajewski, Ritzman e Malhotra (2009), a suavização exponencial é um modelo mais avançado, que combina a previsão anterior com a demanda real mais recente, atribuindo peso decrescente aos dados passados. Por sua simplicidade e pela exigência de poucos dados, é um dos métodos mais utilizados.

Moreira (2011, p. 313) reforça que este modelo é mais sofisticado que os anteriores. A fórmula geral é:

$$DT = \alpha \times Yt - 1 + (1 - \alpha) \times Dt - 1 \quad (6)$$

Onde:

D_t = previsão para o período t

D_{t-1} = previsão anterior

Y_{t-1} = demanda real no período anterior

α = constante de suavização (entre 0 e 1)

Martins sugere o seguinte cálculo para o valor de α , com base no número de períodos:

$$\alpha = \frac{2}{(n+1)} \quad (7)$$

2.5.4 Modelo de tendência e sazonalidade

Martins e Laugen (2005) salientam que para que a previsão de um ajuste sazonal de tendências lineares seja uma reta, deve-se eliminar ou reduzir a influência das variações sazonais e irregulares, como eventos aleatórios e flutuações cíclicas, para que a reta seja apenas a representação da tendência de longo prazo. Isso é feito por meio de técnicas como o pré-ajuste para garantir que o modelo de ajuste sazonal se torne tecnicamente superior.

$$Y_t = T_t + S_t + I_t \quad (8)$$

Onde:

Y_t = valor observado no tempo t ;

T_t = componente tendência (mudança de longo prazo);

S_t = componente sazonal (variação periódica);

I_t = componente irregular (ruído aleatório)

2.5.5 Holt Winter

Nos estudos realizados por Makridakis, Wheelwright e Hyndman (1998), o modelo Holt-Winters é apresentado como um método de suavização exponencial que incorpora uma equação adicional destinada ao ajuste da previsão de sazonalidade. Tal técnica de suavização

exponencial é capaz de considerar séries temporais, abrangendo tanto os registros históricos quanto os componentes sazonais. Para isso, utiliza três parâmetros de alisamento que controlam as dimensões de nível, tendência e sazonalidade.

Morettin e Toloi (1987) destacam que o modelo Holt-Winters fundamenta-se em processos estruturados por meio de três equações distintas, cada uma com constantes de alisamento específicas. Tais equações são diretamente associadas às componentes principais das séries temporais: nível, tendência e sazonalidade.

Segundo a análise realizada por Caiado (2006), o modelo Holt-Winters revela-se particularmente adequado para séries que apresentam comportamento de tendência linear e flutuações sazonais. Entre os métodos desenvolvidos no âmbito do modelo Holt-Winters, destacam-se as abordagens Multiplicativa e Aditiva, ambas concebidas para atender às características e técnicas específicas das análises de séries temporais. Esses métodos serão discutidos com maior profundidade nos tópicos subsequentes.

Conforme Morettin e Toloi (2006), o modelo Holt-Winters aditivo é mais adequado quando a amplitude das flutuações sazonais permanece constante ao longo do tempo, sendo que a componente sazonal é somada ao nível e à tendência da série. Já o modelo multiplicativo é indicado quando a variação sazonal é proporcional ao nível da série, ou seja, cresce ou diminui.

2.6 Medidas de acurácia

A escolha do modelo de previsão depende, entre outros fatores, do nível de precisão desejado. No contexto da previsão de demanda, é essencial avaliar a qualidade das estimativas geradas para garantir decisões mais assertivas. Para entender o quão eficaz é uma determinada abordagem, é necessário estimar o quanto se está errando. Essa análise permite comparar diferentes modelos e selecionar aquele que melhor desempenho.

Root Mean Square Error (RMSE) e o *Mean Absolute Percentage Error (MAPE)* são duas das métricas mais conhecidas e utilizadas na avaliação do desempenho de modelos de previsão de demanda. Ambas têm um papel essencial no diagnóstico da qualidade preditiva dos métodos, pois traduz, em números, o quanto as previsões se aproximam da realidade. O RMSE, segundo Hyndman e Athanasopoulos (2021), mede a raiz quadrada da média dos erros ao quadrado, ou seja, calcula a distância média entre os valores observados e os valores previstos, dando maior peso aos erros de maior magnitude. Sua fórmula pode ser expressa como:

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (17)$$

Onde y_t representa a demanda real, $\hat{y}_t$ a demanda prevista e T o número de observações. De forma simples, quanto menor o RMSE, melhor é o desempenho do modelo, pois indica previsões mais consistentes e próximas dos dados reais (MORETTIN; TOLOI, 2018).

Já o MAPE é um métrico percentual que mede o erro médio absoluto em relação aos valores reais. Sua grande vantagem é permitir uma interpretação mais intuitiva, especialmente para gestores e profissionais que não lidam diretamente com estatística. Segundo Hyndman e Koehler (2006), o MAPE é calculado pela fórmula.

$$MAPE = \frac{100}{T} \sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{y_t} \quad (18)$$

Onde:

T = número de observações

y_t = demanda real $\hat{y}_t$ demanda prevista

3 METODOLOGIA

Este trabalho caracteriza-se como uma pesquisa aplicada, com abordagem quantitativa e qualitativa, de natureza exploratória e descritiva. O objetivo é analisar e propor melhorias no processo de previsão de demanda para um insumo crítico, com foco em comparar os modelos estudados e simular através dos dados disponibilizados pela empresa, identificar a melhor opção para calcular a previsão de demanda.

3.2. Classificação de pesquisa

Gil (2010) destaca que a pesquisa aplicada abrange estudos elaborados com a finalidade de resolver problemas no âmbito das sociedades em que os pesquisadores vivem. Já Gerhardt e Silveira (2009, p. 35) mencionam que “este tipo de pesquisa tem como objetivo gerar conhecimentos para aplicação prática, dirigidos à solução de problemas específicos.” Desta forma, Vergara (2013), aponta que a pesquisa aplicada tem como finalidade a prática e é motivada por uma necessidade imediata ou não.

3.3. Empresa

A empresa em estudo está localizada na Região do Vale do Paraíba, especializada na fabricação de para-brisa automotivo, onde possui um enorme complexo fabril para atendimento das maiores montadoras do mundo. A empresa foi fundada em meados de 1979. Os vidros são produzidos seguindo rigorosos critérios de qualidade, com tecnologia de ponta e altos padrões de segurança, cumprindo assim todos os requisitos determinados pelos principais órgãos certificadores.

3.4. Problema

A empresa vidraceira enfrenta desafios críticos relacionados à gestão de um insumo perecível, importado do Japão e fundamental na fabricação de para-brisas. Os principais problemas identificados estão ligados ao curto prazo de validade do material (6 meses), ao lead time de importação (110 dias).

Apesar do uso de ERP e da aplicação do método FIFO, a empresa ainda depende fortemente de controles manuais em planilhas, o que limita a acuracidade das previsões. Atualmente, a previsão de demanda é realizada por meio do modelo de média simples, o que, embora de fácil aplicação, pode não ser efetiva para esse cenário, e, portanto, contribui para decisões imprecisas de compra e reposição.

Essa limitação, aliada à variabilidade da demanda e à rigidez da cadeia de suprimentos, contribui para o agravamento do efeito chicote, em que pequenas variações na demanda do consumidor final geram grandes distorções nos pedidos ao longo da cadeia, levando a excessos ou faltas de estoque. Tal distorção é crítica considerando o longo tempo de reposição e a curta validade do insumo, resultando em riscos simultâneos de desabastecimento e desperdício.

Em resumo, o cenário atual combina riscos de desabastecimento, desperdício de insumos de alto custo, baixa flexibilidade diante de oscilações do mercado e desafios operacionais que demandam uma revisão nas práticas de previsão e planejamento da cadeia de suprimentos.

3.5. Proposta de solução

A previsão de demanda é uma prática essencial para o planejamento eficiente da cadeia de suprimentos, especialmente em contextos em que o lead time é longo, como no caso

analisado neste trabalho, o tempo de 110 dias impõe desafios adicionais à acuracidade das previsões, exigindo modelos mais robustos e estratégias de mitigação de riscos.

O principal impacto está na limitação da capacidade de resposta da empresa frente às variações inesperadas na demanda. Com um intervalo de mais de três meses entre o pedido e a chegada do material à fábrica, qualquer erro na previsão pode resultar em rupturas de estoque, atrasos na produção ou excesso de inventário, comprometendo a eficiência operacional e a saúde financeira da organização.

Para lidar com essa complexidade, este estudo propõe a substituição do modelo atual de previsão — baseado em média simples — por uma abordagem estatística mais avançada, capaz de incorporar variáveis sazonais, tendências históricas e flutuações de mercado. A simulação será realizada com base em dados reais de demanda entre janeiro de 2023 e fevereiro de 2025, permitindo a comparação entre os resultados previstos e os valores efetivamente registrados.

3.6. Coleta de dados

Os dados foram coletados a partir dos registros históricos do consumo mensal em gramas do Primer disponibilizado pela empresa, considerando um período de janeiro de 2022 a fevereiro de 2025 como base. Esse intervalo foi escolhido pois são suficientes para identificar sazonalidades e tendências, proporcionando maior confiabilidade às previsões.

Com base nos dados históricos de produção fornecidos pela empresa, por meio de planilhas e relatórios, foi realizada uma análise detalhada seguida da aplicação de cálculos e dos principais métodos quantitativos, com o objetivo de estimar o modelo de previsão de demanda que melhor se ajusta aos dados disponíveis. A adoção desses métodos visa minimizar os efeitos da variabilidade, contribuindo para a redução de desperdícios e a prevenção de possíveis rupturas na cadeia produtiva.

3.7. Ferramenta utilizada

Para a realização das análises e cálculos de previsão de demanda, foi utilizada a ferramenta Microsoft Excel, amplamente adotada no meio acadêmico e corporativo por sua versatilidade e capacidade de tratamento de dados. Segundo Lima (2020), o Excel é um recurso eficiente para o desenvolvimento de modelos quantitativos, pois permite a aplicação de fórmulas estatísticas, análise de sensibilidade e construção de gráficos de apoio à decisão de forma acessível e visual.

O uso do Excel possibilitou a criação de planilhas automatizadas para cálculo de média simples, suavização exponencial, tendência e sazonalidade, além da implementação do método de Holt-Winters para previsões de séries temporais. As principais fórmulas utilizadas no processo foram:

- MÉDIA: aplicada para o cálculo da média simples, representando a soma dos valores históricos dividida pela quantidade de períodos. Essa função serviu como base para comparação com métodos mais avançados de previsão.
- INCLINAÇÃO: utilizada para determinar a taxa de variação ou tendência da série temporal, indicando o crescimento ou decréscimo ao longo do tempo.
- INTERCEPÇÃO: usada para calcular o ponto de interseção da reta de tendência no eixo Y, auxiliando na projeção linear da demanda.
- ABS: função auxiliar que retorna o valor absoluto, aplicada na mensuração de erros entre o valor previsto e o real, evitando distorções negativas.
- RAIZ: empregada no cálculo do erro quadrático médio (RMSE), permitindo avaliar o desempenho dos modelos de previsão.
- PROCV: utilizada como formula auxiliar para buscar e retornar um valor em uma tabela com base em uma correspondência na primeira coluna.

Além dessas funções, o Excel foi utilizado para a construção de gráficos de linhas e colunas, fundamentais para a visualização das tendências históricas e o comportamento sazonal da demanda. Essa etapa permitiu identificar padrões e validar os resultados obtidos com os modelos de previsão.

Também foi utilizado o complemento solver, ferramenta que possibilita a otimização de variáveis. No presente trabalho, o Solver foi aplicado para minimizar o valor do parâmetro alfa (α) nos modelos de suavização exponencial, buscando reduzir o erro médio absoluto e aumentar a acuracidade da previsão. Conforme Morettin e Toloi (2018), a suavização exponencial requer a escolha adequada dos parâmetros de suavização (α , β e γ), os quais impactam diretamente na sensibilidade do modelo às variações recentes da demanda.

- Os métodos implementados no Excel contemplaram as seguintes abordagens de previsão:
- Média simples: cálculo básico da média dos períodos anteriores para projeção do valor futuro.

- Suavização exponencial simples: aplicação de um peso (α) maior aos valores mais recentes, foi utilizado otimização via solver.
- Tendência e Sazonalidade: decomposição da série em componentes, utilizando as funções INCLINAÇÃO e INTERCEPÇÃO para identificar tendências lineares, e ajustes periódicos para captar o comportamento sazonal.

Método de Holt-Winters: modelo mais avançado de previsão, que considera simultaneamente tendência e sazonalidade, ajustado por parâmetros de suavização (α , β , γ). Esse método foi operacionalizado com auxílio de planilhas personalizadas e otimização via solver.

Dessa forma, o Excel demonstrou ser uma ferramenta eficaz para o tratamento dos dados e o desenvolvimento de modelos de previsão aplicados à logística, permitindo análises quantitativas de forma prática e visualmente interpretável.

3.8. Aplicação dos métodos quantitativos

Com o objetivo de estimar o modelo de previsão de demanda mais adequado à realidade da empresa, foi aplicada a simulação os seguintes métodos quantitativos:

- Média Móvel Simples;
- Suavização Exponencial;
- Tendência + Sazonalidade;
- Holt-Winter.

A ideia foi analisar o consumo durante o tempo, observar tendências e sazonalidade, comparar o desempenho de cada modelo e identificar qual oferece maior precisão para a realidade operacional. A escolha desses modelos baseou-se em sua relevância acadêmica, ampla aplicabilidade no ambiente corporativo e compatibilidade com as ferramentas atualmente utilizadas pela empresa. Além disso, por serem modelos relativamente simples de implementar, representam uma alternativa viável.

O primeiro passo consistiu na organização e tratamento dos dados históricos de consumo, referente ao período entre janeiro de 2022 a fevereiro de 2025 para se calcular e simular a previsão de janeiro de 2023 a fevereiro de 2025. Após isso, foram realizados os cálculos através do Excel, a fim de identificar aquele que apresentasse o melhor desempenho em relação à demanda real observado. A partir dessa comparação, foi calculada a RMSE e o

MAPE permitindo identificar o modelo com menor variação em relação à demanda observada e, conseqüentemente, o mais adequado para o conjunto de dados analisado.

4 RESULTADOS E DISCUSSÕES


4.1 Simulações dos modelos quantitativos

A figura 2 apresenta a simulação da previsão de demanda obtida por meio do modelo de média simples, método atualmente utilizado pela empresa para estimar o consumo do insumo analisado. No gráfico, observa-se a relação entre os valores reais de consumo e os valores previstos pelo modelo ao longo do período avaliado. A linha azul representa o consumo real do insumo, enquanto a linha vermelha indica os valores estimados pela média simples.

Visualmente, percebe-se que o modelo consegue acompanhar a tendência geral da demanda, mas verifica-se uma limitação significativa na sua capacidade de capturar variações sazonais, como os picos e quedas observados em meses específicos, a exemplo de fevereiro e novembro. Essa característica é comum em modelos de média simples, uma vez que o método se baseia exclusivamente em valores passados, atribuindo o mesmo peso a todas as observações, o que o torna menos sensível a mudanças repentinas na demanda.

Apesar de sua simplicidade e fácil aplicabilidade, o modelo de média simples tende a apresentar erro quando a série temporal apresenta comportamento sazonal ou irregular. Assim, sua utilização se mostra mais adequada em contextos de estabilidade de consumo.

Figura 2 – Simulação com o modelo Média Simples




Fonte: Elaborado pelos autores, com base nos dados (2025)

A figura 3 apresenta a simulação da previsão de demanda utilizando o modelo de suavização exponencial. No gráfico, a linha azul representa o consumo real (em gramas), enquanto a linha vermelha indica os valores previstos pelo modelo ao longo do período analisado.

Para a aplicação do modelo, foi utilizado o recurso Solver do Microsoft Excel, com o objetivo de determinar o valor ótimo do parâmetro de suavização (α) que minimizasse o erro das previsões. O resultado obtido para o parâmetro foi $\alpha = 0,39236$, indicando que o modelo atribui cerca de 39% de peso aos dados mais recentes.

Visualmente, percebe-se que o modelo acompanha a tendência geral do consumo, apresentando variações mais suaves ao longo do tempo. Contudo, assim como a média simples, demonstra certas limitações ao capturar flutuações sazonais. Em alguns períodos o consumo real registra picos ou quedas significativas que não são integralmente refletidos pelas previsões. Isso ressalta que, apesar de sua eficiência em identificar tendências amplas, o modelo enfrenta dificuldades em responder com precisão às variações abruptas da demanda.

Figura 3 – Simulação com o modelo Suavização Exponencial



Fonte: Elaborado pelos autores, com base nos dados (2025)

A figura 4 exibe uma simulação da previsão de demanda com base em um modelo que leva em consideração tanto a tendência quanto a sazonalidade do consumo. No gráfico, a linha azul representa os dados reais de consumo (em gramas), enquanto a linha vermelha indica a tendência estimada ao longo do tempo, e a linha verde mostra os valores projetados pelo modelo.

Nota-se que o modelo acompanha bem a tendência geral do consumo e, ao contrário do modelo anterior, demonstra maior habilidade em capturar as variações sazonais. A linha de previsão (verde) se aproxima mais dos picos e quedas observados no consumo real, como nos meses de março, julho e novembro do primeiro ano, assim como em agosto e dezembro do segundo ano. Embora ainda existam pequenas divergências, especialmente em períodos de mudanças mais abruptas, o desempenho do modelo mostra-se mais consistente na identificação de padrões sazonais. Isso evidencia que a inclusão da componente sazonal contribui significativamente para melhorar a precisão das previsões quando comparado ao modelo de suavização exponencial simples.




Figura 4 – Simulação com o modelo Tendência e Sazonalidade
Fonte: Elaborado pelos autores, com base nos dados (2025)


A aplicação do modelo de Holt-Winters na simulação de previsão de demanda revela um método eficaz para considerar simultaneamente os componentes de tendência e sazonalidade de forma equilibrada e precisa. Na análise gráfica, a linha azul representa os valores reais de consumo (em gramas), enquanto a linha vermelha indica as estimativas geradas pelo modelo ao longo do período avaliado.

No modelo Holt-Winters, os parâmetros de suavização alfa (α), beta (β) e gama (γ) foram determinados por meio do Solver, buscando minimizar o erro das previsões. O valor de $\alpha = 0,9263$ indica que o modelo atribui maior peso às observações mais recentes, tornando-o altamente responsivo às variações atuais da demanda. O $\beta = 0,3011$ ajusta a tendência de forma moderada, garantindo estabilidade ao modelo, enquanto o $\gamma = 0,5779$ controla a influência da sazonalidade, permitindo captar oscilações periódicas sem exagerar sua intensidade. A

calibração automatizada desses parâmetros resultou em previsões mais precisas e alinhadas ao comportamento real da demanda, reforçando a eficácia do método Holt-Winters no contexto analisado.

Visualmente, fica evidente que um bom desempenho do modelo na aproximação dos valores reais, apresentando precisão na representação da tendência geral do consumo e nas oscilações sazonais. A previsão, ilustrada pela linha vermelha, reproduz com fidelidade os picos e quedas no consumo real, como nos meses de março, julho e novembro no primeiro ano, além de agosto, dezembro e janeiro no segundo ano. Há diferenças entre os valores reais e os estimados, mas são menores em relação aos outros testados. Sua capacidade de adaptação rápida às variações sazonais e às tendências consolida sua utilidade como uma ferramenta confiável para a previsão de demanda.

Figura 5 – Simulação com o modelo Holt-Winter



Fonte: Elaborado pelos autores, com base nos dados (2025)

4.2. RMSE e MAPE

Para selecionar o modelo mais adequado à previsão de demanda, utilizou-se como principal métrica o Erro Percentual Absoluto Médio (MAPE), por sua fácil interpretação e capacidade de expressar o erro em termos relativos. O MAPE permite comparar a acurácia entre modelos, independentemente da escala dos dados, sendo o modelo com menor valor na fase de teste considerado o mais eficiente. Complementarmente, foi calculado o Erro

Quadrático Médio da Raiz (RMSE), visando avaliar o desempenho em termos absolutos. Os resultados foram organizados de acordo com a Tabela 1.

Tabela 1 – Resultado da eficiência por modelo de previsão

Modelo de previsão	RMSE	% RMSE	% MAPE
Média Simples	2163	31%	19%
Tendência Sazonalidade	1533	22%	14%
Suavização Exponencial	2081	30%	19%
Holt-Winter	1112	16%	9%

Fonte: Elaborado pelos autores, com base nos dados (2025)

Observa-se que o modelo Holt-Winters apresentou o melhor desempenho entre as metodologias avaliadas, com RMSE de 1112 e MAPE de 9%, indicando elevada acurácia e menor desvio em relação aos valores reais. Esse resultado demonstra a eficiência do modelo em capturar variações sazonais e tendências do consumo, aspecto especialmente relevante para insumos perecíveis, cuja demanda tende a oscilar em função de fatores externos e períodos específicos do ano.

O modelo de Tendência com Sazonalidade obteve o segundo melhor resultado, apresentando RMSE de 1533 e MAPE de 14%, revelando boa capacidade de ajuste aos padrões históricos, embora com menor sensibilidade a flutuações pontuais. Em contrapartida, os modelos de Média Simples e Suavização Exponencial demonstraram desempenho inferior, com RMSEs acima de 2000 e MAPE em torno de 19%, refletindo menor precisão e maior dispersão das previsões em relação aos dados observados.

De modo geral, os resultados evidenciam que modelos que consideram tendência e sazonalidade proporcionam previsões mais coerentes com o comportamento real da demanda. Assim, recomenda-se a adoção do método Holt-Winters como principal ferramenta de previsão para a empresa estudada, visto que seu desempenho estatístico confere maior confiabilidade ao planejamento de compras e à gestão de estoques, reforçando a necessidade de revisão do modelo atualmente utilizado.

Compreender o comportamento da demanda é fundamental para a eficiência da cadeia de suprimentos, pois impacta diretamente decisões de compra, programação de produção e atendimento ao cliente. Contudo, a demanda é um fenômeno dinâmico, sujeito a influências como mudanças no comportamento do consumidor, sazonalidades e variações econômicas. Nesse contexto, depender de modelos simples pode ser arriscado, pois tais abordagens ignoram

padrões e oscilações relevantes, resultando em decisões menos assertivas. A aplicação de métodos avançados de previsão, como o Holt-Winters, contribui para aumentar a precisão e a capacidade de resposta da empresa frente às variações do mercado, fortalecendo o planejamento estratégico e a competitividade organizacional.

A integração de sistemas de informação, como ERPs e plataformas colaborativas, também desempenha um papel crucial ao facilitar o fluxo de informações e promover uma cadeia mais transparente e sincronizada. Quando todos os agentes têm acesso aos mesmos dados em tempo real, as decisões tornam-se mais racionais e estratégicas, reduzindo a variabilidade dos pedidos e, conseqüentemente, minimizando o impacto negativo do efeito chicote.

Em suma, entender que a demanda é dinâmica e que a previsão deve ser constantemente revisada, além de garantir uma comunicação eficaz e integrada entre os elos da cadeia, são estratégias essenciais para evitar estoques desnecessários, prevenir rupturas e melhorar a eficiência global da cadeia de suprimentos. Empresas que adotam essas práticas estão mais preparadas para lidar com incertezas, reduzir riscos e manter sua competitividade no mercado, especialmente em setores com produtos perecíveis, fornecedores exclusivos e longos tempos de reposição.

4.3 Dados utilizados

Tabela 2 – Demanda real do *Primer* em gramas

Ano	Mês	Consumo (g)
2022	Janeiro	3.150,55
2022	Fevereiro	2.526,80
2022	Março	4.633,51
2022	Abril	3.469,27
2022	Maio	3.807,40
2022	Junho	2.974,87
2022	Julho	5.533,91
2022	Agosto	5.872,21
2022	Setembro	5.373,08
2022	Outubro	4.486,72
2022	Novembro	8.784,22
2022	Dezembro	3.302,31
2023	Janeiro	6.126,72
2023	Fevereiro	7.340,50

2023	Março	12.287,90
2023	Abril	8.289,79
2023	Maio	8.331,51
2023	Junho	9.117,85
2023	Julho	6.208,16
2023	Agosto	10.051,70
2023	Setembro	7.604,73
2023	Outubro	7.019,27
2023	Novembro	7.837,36
2023	Dezembro	4.562,62
2024	Janeiro	4.933,72
2024	Fevereiro	8.592,61
2024	Março	9.177,54
2024	Abril	8.908,30
2024	Maio	8.973,55
2024	Junho	8.639,68
2024	Julho	9.679,20
2024	Agosto	11.773,91
2024	Setembro	9.987,31
2024	Outubro	12.807,11
2024	Novembro	11.008,25
2024	Dezembro	7.682,40
2025	Janeiro	9.422,80
2025	Fevereiro	11.150,53

Fonte: Dados fornecidos pela empresa estudada, adaptados pelos autores (2025)

5 CONCLUSÃO

Diante dos desafios enfrentados pela empresa vidraceira na gestão de um insumo perecível e estratégico, torna-se evidente que a previsibilidade da demanda desempenha um papel central na eficiência da cadeia de suprimentos. A utilização de modelos simples, como a média aritmética, embora prática revela-se insuficiente frente à complexidade operacional, ao longo lead time de importação e à variabilidade do consumo.

A proposta deste trabalho, ao sugerir a adoção de modelos preditivos mais avançados e a realização de simulações comparativas com a demanda real, busca evidenciar como uma abordagem mais robusta pode reduzir riscos de desperdício, minimizar faltas de insumo e melhorar a tomada de decisão.

Entretanto, a precisão na previsão não é suficiente por si só. A integração entre previsão e comunicação eficiente em toda a cadeia de suprimentos é o que de fato transforma os dados

em ações estratégicas. Quando os diversos setores da empresa e os parceiros externos compartilham informações em tempo real, é possível agir de forma mais coordenada e proativa, reduzindo significativamente o impacto do efeito chicote.

Assim, este estudo reforça que a combinação entre tecnologia, análise inteligente de dados e comunicação transparente é o caminho para uma gestão mais eficiente e alinhada com as exigências de um mercado dinâmico. Investir em previsões mais precisas e fortalecer a colaboração na cadeia não é apenas uma melhoria operacional é uma vantagem competitiva.

REFERÊNCIAS

- ANZANELLO, M. J.; FOGLIATTO, F. S. Previsão de demanda: conceitos, métodos e aplicações na indústria. Porto Alegre: Ed. UFRGS, 2010.
- BALLOU, Ronald H. Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial. 5. ed. Porto Alegre: Bookman, 2001.
- BALLOU, Ronald H. Logística Empresarial: transporte, administração de materiais e distribuição física. 1. ed. São Paulo: Atlas, 2006.
- BOWERSOX, D. J.; CLOSS, D. J.; COOPER, M. B. Gestão da cadeia de suprimentos e logística. 4. ed. Rio de Janeiro: Elsevier, 2014.
- CHIAVENATO, Idalberto. Administração de materiais e recursos patrimoniais. 2. ed. Rio de Janeiro: Elsevier, 2005.
- CHOPRA, Sunil; MEINDL, Peter. Supply Chain Management: Strategy, Planning, and Operation. Upper Saddle River, NJ: Prentice Hall, 2001.
- CHOPRA, S.; MEINDL, P. Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operação. 8. ed. São Paulo: Pearson, 2021.
- CHRISTOPHER, Martin. Logística e Gerenciamento da Cadeia de Suprimentos: Estratégia, Planejamento e Operação. 4. ed. São Paulo: Cengage Learning, 2011.
- CHRISTOPHER, M. Logística e gerenciamento da cadeia de suprimentos. 4. ed. São Paulo: Cengage Learning, 2016.
- CORRÊA, H. L.; CORRÊA, C. A. Administração de produção e operações: manufatura e serviços – uma abordagem estratégica. 3. ed. São Paulo: Atlas, 2012.
- CORRÊA, Henrique L.; GIANESI, Irineu G. N.; CAON, Mauro. Planejamento, programação e controle da produção: MRP II/ERP: conceitos, uso e implantação. 5. ed. São Paulo: Atlas, 2001.
- DIAS, Marco Aurélio P. Gestão de estoques: como diminuir custos e aumentar o nível de serviço. 2. ed. São Paulo: Atlas, 2010. 256 p

GARCIA, E. S; LACERDA, L. S; AROZO, R.B. Gerenciando incertezas no planejamento logístico: o papel do estoque de segurança. Revista Tecnológica, São Paulo, v. 63, p. 36-42, fev. 2001.

GONÇALVES, Paulo Sérgio. Administração de Materiais. 6. ed. São Paulo: Atlas, 2020

HUBER, Beatris. Lote Econômico de Compra na prática. ILOS Insights, ILOS. Disponível em: ILOS. Acesso em: 3 set. 2025.

KAPLAN, Robert S.; NORTON, David P. Execution Premium: Linking Strategy to Operations for Competitive Advantage. Boston: Harvard Business Press, 2008.

KRAJEWSKI, Lee J.; RITZMAN, Larry P.; MALHOTRA, Manoj K. Administração da produção e operações. 8. ed. São Paulo: Pearson Prentice Hall, 2009.

LAUGENI, Fernando Piero; MARTINS, Petrônio Garcia. Administração da produção. 3. ed. São Paulo: Saraiva, 2015. p. 235.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. Forecasting: Methods and Applications. 3. ed. New York: John Wiley & Sons, 1998.

MARTINS, Petrônio Garcia; LAUGENI, Fernando Piero. Administração da produção. 2. ed. São Paulo: Saraiva, 2005.

McKINNEY, Wes. Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython. 2. ed. Sebastopol: O'Reilly Media, 2018.

MOREIRA, Daniel Augusto. Administração da produção e operações. 2. ed. São Paulo: Cengage Learning, 2008.

MORETTIN, P. A.; TOLOI, C. M. Análise de Séries Temporais. 3. ed. São Paulo: Blucher, 2018.

TUMENAS, Filipe. *Tendência e sazonalidade*. Disponível em: <https://www.youtube.com/watch?v=PjRNnOhPO0A>. Acesso em: 15/10/2025

TUMENAS, Filipe. Previsão com o método Holt–Winters (exponencial tripla) – passo a passo.. Disponível em: <https://www.youtube.com/watch?v=JqbaRku48YY&t=1014s> . Acesso em: 15/10/2025

ROSSETTO, M; DEIMLING, M. F; ZANIN, A. RODRIGUES, M. P; NETO, A. R. Técnicas Qualitativas de Precisão de Demanda: um Estudo Multicasos com Empresas do Ramo de Alimentos. VIII SEGeT – Simpósio de Excelência em Gestão e Tecnologia, outubro de 2011.

SILVA, Bráulio Wilker. Gestão de estoques: planejamento, execução e controle. 1. ed. [s.l]: [s.n.], 2019.

SILVA, Fernando da. As diferentes formas de avaliar o erro de um modelo de previsão. Análise Macro, 01 nov. 2024. Disponível em: <https://analisemacro.com.br/econometria-e-machinelearning/as-diferentes-formas-de-avaliar-o-erro-de-um-modelo-de-previsao/> Acesso em: 12/09/2025

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

TPC. Confira agora o que é FIFO e como funciona esse sistema de armazenamento. Disponível em: <<https://www.grupotpc.com/blog/o-que-e-fifo/>>. Acesso em: 09/06/2025

TPC. Entenda o que é FEFO e sua diferença para o FIFO. Disponível em: <<https://www.grupotpc.com/blog/o-que-e-fefo/> e sua diferença para o FIFO > Acesso em: 09/06/2025.

TUBINO, Dalvio Ferrari. Planejamento e controle da produção: teoria e prática. 9. ed. São Paulo: Atlas, 2017.

VANDERPLAS, Jake. Python Data Science Handbook: Essential Tools for Working with Data. 1. ed. Sebastopol: O'Reilly Media, 2016.

WERNER, Liane. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2004. Tese de Doutorado em Engenharia de Produção.