

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE GESTÃO E NEGÓCIOS
CURSO DE ADMNISTRAÇÃO

MARESSA PAULA DA SILVA

*Seleção de modelos preditivos em operações: aplicação do Desvio Médio
Absoluto como métrica de validação*

UBERLÂNDIA-MG
2025

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

MARESSA PAULA DA SILVA

*Seleção de modelos preditivos em logística: aplicação do Desvio Médio
Absoluto como métrica de validação*

Trabalho de Conclusão de Curso apresentado a Faculdade de Gestão e Negócios da Universidade Federal de Uberlândia como requisito parcial para obtenção do título de bacharel em Administração. Área de Pesquisa: Operações.

Orientadora: Profª. Dra. Valeriana Cunha

UBERLÂNDIA-MG
2025

BANCA EXAMINADORA

Seleção de modelos preditivos em logística: aplicação do Desvio Médio Absoluto como métrica de validação

Trabalho de Conclusão de Curso apresentado a Faculdade de Gestão e Negócios da Universidade Federal de Uberlândia como requisito parcial para obtenção do título de bacharel em Administração. Área de Pesquisa: Operações.

Orientadora: Profª. Dra. Valeriana Cunha

Uberlândia, 12 de maio de 2025.

Banca Examinadora

Orientadora Profa. Dra. Valeriana Cunha (UFU)

Prof. Dr. Cristiano Augusto Borges Forti (UFU)

Prof. Dr. Eustáquio São José de Faria (UFU)

AGRADECIMENTOS

Gostaria de expressar minha sincera gratidão a todas as pessoas que, de alguma forma, contribuíram para a realização deste trabalho.

À minha mãe, Marilia, meu alicerce obrigado por regar com amor o sonho de cursar uma faculdade e por nunca duvidar do meu potencial. Se hoje colho os frutos deste trabalho, é porque você plantou em mim a semente da perseverança e do amor pelo conhecimento.

À minha orientadora, Valeriana Cunha, pela paciência, dedicação e orientação valiosa em cada etapa deste projeto. Suas críticas, incentivos e compreensão foram fundamentais para a conclusão deste trabalho.

E ao meu marido Raphael meu companheiro de todas as horas obrigada por segurar minha mão nos dias de cansaço, por celebrar cada pequena conquista e por renovar minha força quando eu pensava que não era mais possível acreditar, obrigada por ser meu maior apoio e a prova de que, juntos, podemos tornar qualquer jornada em uma memória digna de orgulho.

RESUMO

Este trabalho analisa a eficácia de diferentes métodos de previsão de demanda aplicados a um marketplace regional que utiliza cross-docking como estratégia logística. Foram comparados três modelos: o atual utilizado pela empresa, a regressão linear simples e o método de Holt-Winters aditivo, com base no cálculo do Desvio Médio Absoluto (DMA). Os resultados demonstram que o Holt-Winters, por integrar tendência e sazonalidade, apresentou maior acurácia (DMA de 7.623,78 contra 8.750,67 do modelo interno e 13.593,17 da regressão linear). A análise evidenciou que previsões precisas são significativas para reduzir problemas operacionais e otimizar recursos logísticos. Conclui-se que a adoção de modelos robustos, alinhados a padrões sazonais, melhora a eficiência operacional e reduz custos, reforçando a importância de técnicas avançadas para o planejamento em cadeias de suprimentos dinâmicas.

Palavras-chave: Previsão de demanda; Holt-Winters; Cross-docking; DMA; Logística.

ABSTRACT

This study analyzes the effectiveness of different demand forecasting methods applied to a regional marketplace that employs cross-docking as a logistics strategy. Three models were compared: the company's current internal model, simple linear regression, and the additive Holt-Winters method—based on Mean Absolute Deviation (MAD) calculations. The results demonstrate that Holt-Winters, by incorporating trend and seasonality, achieved higher accuracy (MAD of 7,623.78 compared to 8,750.67 for the internal model and 13,593.17 for linear regression). The analysis revealed that precise forecasts are critical to mitigating operational issues and optimizing logistics resources. In conclusion, adopting robust models aligned with seasonal patterns enhances operational efficiency and reduces costs, underscoring the importance of advanced techniques for planning in dynamic supply chains.

Keywords: Demand forecasting; Holt-Winters; Cross-docking; MAD; Logistics.

1 Introdução

Nas últimas décadas, as transformações tecnológicas e o avanço da digitalização remodelaram profundamente a forma como produtos são comercializados e entregues aos consumidores. Em meio a esse cenário em constante evolução, compreender as dinâmicas logísticas e os desafios associados à previsão de demanda tornou-se essencial para garantir a eficiência operacional das empresas. Este estudo propõe uma reflexão sobre essas questões a partir da análise de um *marketplace* regional, com foco em estratégias que promovam maior alinhamento entre oferta e demanda.

1.1 Contextualização do Tema

O comércio eletrônico tem experimentado um crescimento exponencial nas últimas décadas, impulsionado pela digitalização e pela mudança no comportamento dos consumidores. Nesse contexto, os *marketplaces* consolidaram-se como plataformas centrais, conectando vendedores e compradores em ambientes virtuais dinâmicos e diversificados. Empresas como Amazon, Mercado Livre e Shopee ilustram como esse modelo de negócio pode escalar operações e oferecer uma ampla variedade de produtos com agilidade. No entanto, a eficiência dessas plataformas depende diretamente de sua capacidade logística, especialmente no que se refere ao gerenciamento de estoques e à distribuição de mercadorias (Kotler; Kartajaya, 2021).

Dentro da cadeia de suprimentos, a logística desempenha um papel crucial, garantindo que os produtos cheguem ao consumidor final dentro prazo e com o menor custo possível. Uma das estratégias mais eficazes para otimizar esse processo é o *cross-docking*, que elimina a necessidade de armazenamento prolongado, transferindo as mercadorias diretamente do recebimento para a expedição. Essa abordagem reduz custos operacionais e acelera o ciclo de entregas, mas exige elevado nível de sincronização entre fornecedores, centros de distribuição e transportadoras (Bowersox; Closs; Cooper, 2020).

Nesse cenário, a previsão de demanda surge como um elemento essencial para o sucesso do *cross-docking*, uma vez que a estratégia depende da capacidade de antecipar picos de consumo e ajustar a operação logística em tempo real. Modelos estatísticos e técnicas de *machine learning* têm sido amplamente utilizados para analisar dados históricos e identificar padrões sazonais, como o aumento das vendas em datas de alta demanda, como o Dia das Mães, a *Black Friday* e o Natal (Hyndman; Athanasopoulos, 2018). Sem uma previsão precisa, as

empresas ficam vulneráveis ao excesso de estoque, a atrasos nas entregas ou, no pior cenário, a rupturas no fornecimento.

No contexto de um *marketplace* regional, como o analisado neste estudo, que atende cidades do Triângulo Mineiro, a previsão de demanda torna-se ainda mais desafiadora devido às especificidades do mercado local. Fatores como sazonalidade econômica, comportamento do consumidor regional e promoções específicas podem influenciar diretamente as vendas. Dados históricos demonstram que, independentemente da localidade analisada, em meses como maio, julho e dezembro, há picos de demanda que exigem um planejamento logístico mais robusto (Chopra; Meindl, 2021).

O presente trabalho tem como objetivo principal evidenciar a importância da previsão de demanda no contexto da gestão logística, especialmente em operações que adotam estratégias de distribuição ágeis, como o *cross-docking*. Nesse sentido, será apresentada a previsão atualmente utilizada pela empresa objeto de estudo, a qual serve como base para o dimensionamento de suas operações mensais. Em paralelo, serão aplicados dois modelos alternativos de previsão: o modelo de regressão linear simples e o modelo de Holt-Winters aditivo, que incorpora componentes de nível, tendência e sazonalidade, sendo amplamente utilizado para séries temporais com comportamento cíclico.

Após a geração das previsões pelos três métodos, será realizada uma análise comparativa de sua acurácia, por meio do cálculo do desvio médio absoluto (DMA), que permite quantificar o erro médio entre os valores previstos e os valores efetivamente observados. A partir dessa comparação, busca-se identificar qual modelo apresenta melhor desempenho preditivo, oferecendo subsídios para a adoção de práticas mais eficazes no planejamento logístico da organização.

1.2 Justificativa

A previsão de demanda constitui um dos pilares da gestão logística contemporânea, especialmente em ambientes altamente competitivos como os *marketplaces*. Erros nas estimativas de vendas podem acarretar custos elevados com estoque excedente ou, inversamente, à indisponibilidade de produtos, comprometendo a experiência do cliente. Segundo Christopher (2016), empresas que adotam modelos preditivos avançados conseguem reduzir em até 30% os custos logísticos, evidenciando o impacto direto dessa prática na rentabilidade do negócio.

No caso específico do *cross-docking*, a ausência de previsões precisas pode comprometer toda a operação. Como essa estratégia depende da sincronização perfeita entre a entrada e a saída de mercadorias, qualquer desvio entre a demanda real e a prevista pode gerar gargalos, atrasos e aumento dos custos de transporte (Lambert; Stock; Ellram, 2021). Assim, o desenvolvimento de um modelo estatístico confiável deixa de ser apenas uma vantagem competitiva e passa a ser uma necessidade operacional.

Além disso, a análise de dados históricos permite identificar padrões sazonais e tendências de consumo, sendo essencial para o planejamento de promoções e campanhas de marketing. Sem um modelo que antecipe tais padrões, a empresa corre o risco de subdimensionar sua capacidade logística, gerando insatisfação dos clientes (Waters; Rinsler, 2022).

Segundo Corrêa e Corrêa (2012), a sazonalidade é um dos principais componentes da demanda e deve ser considerada nos processos de previsão, pois representa variações sistemáticas e recorrentes ao longo do tempo, muitas vezes associadas a eventos culturais, econômicos ou climáticos.

Outro aspecto relevante é a otimização de recursos. Em um cenário onde a logística se torna um diferencial competitivo, *marketplaces* que conseguem prever demandas com maior precisão podem negociar melhores condições com transportadoras, reduzir a ociosidade de veículos e diminuir o desperdício de embalagens e insumos. Isso não apenas melhora a eficiência operacional, mas também contribui para a sustentabilidade (Rushton; Croucher; Baker, 2022).

Este estudo justifica-se tanto pela relevância teórica quanto empírica de seus achados, ao integrar técnicas de previsão de demanda a dados históricos com o intuito de embasar decisões logísticas. A previsão de demanda eficaz pode gerar inúmeros benefícios às operações baseadas em *cross-docking*, promovendo eficiência sistêmica e alinhamento estratégico entre diferentes departamentos da empresa.

2 Referencial Teórico

2.1 Marketplaces e Logística

Os marketplaces representam um dos modelos de negócio mais disruptivos no comércio eletrônico contemporâneo. Essas plataformas funcionam como mercados digitais que conectam múltiplos vendedores a consumidores em um único ambiente virtual, oferecendo desde produtos cotidianos até itens especializados.

Segundo Kotler e Kartajaya (2021), essa estrutura permite que pequenos e médios empreendedores alcancem um público amplo sem a necessidade de investir em infraestrutura própria de e-commerce, enquanto os compradores se beneficiam da conveniência de comparar preços e variedade em um só lugar. Grandes players globais, como Amazon, Mercado Livre e Alibaba, demonstram a escalabilidade desse modelo, que atualmente responde por uma parcela significativa das vendas online em todo o mundo.

No entanto, o sucesso de um marketplace depende criticamente da eficiência logística. Diferentemente das lojas virtuais tradicionais, onde a gestão de estoques e entregas é centralizada, os marketplaces operam com uma rede fragmentada de vendedores, cada um com seus próprios processos e prazos. Essa heterogeneidade gera desafios, como a despadronização dos prazos de entrega e a dificuldade em garantir a qualidade do serviço pós-venda (Fernie; Sparks, 2019).

Além disso, a expectativa dos consumidores por entregas rápidas e gratuitas — impulsionada por gigantes como a Amazon, por meio do serviço Prime — impõe pressão adicional sobre a cadeia de suprimentos.

Um dos principais desafios logísticos nesse contexto é a gestão de estoques distribuídos. Como os produtos estão fisicamente localizados em diferentes pontos — seja em centros de distribuição dos próprios vendedores, seja em armazéns terceirizados —, a coordenação para garantir entregas ágeis torna-se complexa. A solução adotada por muitos marketplaces tem sido o modelo de *fulfillment* centralizado, no qual a própria plataforma assume a armazenagem e expedição dos produtos em nome dos vendedores. Essa abordagem, conforme apontam Rushton et al. (2022), reduz o tempo de entrega e padroniza a experiência do cliente, embora exija investimentos significativos em infraestrutura e tecnologia.

Outro obstáculo relevante é a chamada "última milha", etapa final da entrega, conhecida por seus altos custos e complexidade operacional. Em marketplaces que atendem regiões com ampla diversidade geográfica — como o Triângulo Mineiro, foco deste estudo —, fatores como densidade populacional, condições das vias e disponibilidade de transportadoras impactam diretamente a eficiência da operação. Estratégias como roteirização inteligente, parcerias com logtechs e pontos de retirada automatizados têm sido adotadas para mitigar esses desafios (Waters; Rinsler, 2022).

Nesse contexto, a previsão de demanda surge como um pilar fundamental para enfrentar os desafios logísticos. Sem estimativas precisas do volume de pedidos, os marketplaces enfrentam dois riscos críticos: o excesso de estoque — que eleva os custos de armazenagem — e a ruptura de produtos, que compromete a reputação e a experiência do

cliente. Como destacam Chopra e Meindl (2021), plataformas que integram dados históricos com variáveis externas, como sazonalidade e indicadores econômicos, conseguem equilibrar melhor essa equação. No caso específico de operações baseadas em *cross-docking*, nas quais a sincronização entre recebimento e expedição é essencial, a acurácia da previsão torna-se ainda mais determinante para evitar gargalos e custos com transporte emergencial (Bowersoz et al., 2020).

Em síntese, embora os marketplaces tenham democratizado o acesso ao comércio eletrônico, sua sustentabilidade depende da capacidade de transformar desafios logísticos em vantagens competitivas. Investimentos em tecnologia, parcerias estratégicas e modelos preditivos robustos são essenciais para alinhar a crescente complexidade operacional às expectativas do consumidor moderno por velocidade, transparência e confiabilidade.

2.2 Cross-Docking: Estratégia Logística para Agilidade e Eficiência: conceito e aplicação.

O *cross-docking* é uma estratégia logística inovadora que elimina ou reduz drasticamente a necessidade de armazenagem tradicional. Como definem Nogueira (2012) e Alves (2000), trata-se de um sistema em que as mercadorias recebidas dos fornecedores são imediatamente classificadas, reorganizadas e direcionadas aos veículos de expedição, sem passar por um período significativo de estocagem. Essa abordagem foi inicialmente desenvolvida pela Walmart na década de 1980 e, desde então, tem sido amplamente adotada por empresas que buscam otimizar suas cadeias de suprimentos, especialmente no varejo e no comércio eletrônico.

Na prática, o *cross-docking* pode ser implementado em diferentes configurações:

- **Cross-docking direto:** as mercadorias são transferidas diretamente do caminhão de recebimento para o veículo de entrega.
- **Cross-docking consolidado:** produtos de múltiplos fornecedores são combinados para formar cargas completas com destino comum.
- **Cross-docking híbrido:** combina elementos dos dois modelos anteriores, permitindo pequenos períodos de *buffer* quando necessário.

A implementação eficaz do *cross-docking* oferece diversas vantagens estratégicas:

1. **Redução de custos operacionais:** elimina despesas com armazenagem prolongada, reduzindo custos com aluguel de espaço, mão de obra de estocagem e perdas por obsolescência (Nogueira, 2012).
2. **Agilidade no ciclo de distribuição:** os produtos podem chegar ao cliente final em até 50% menos tempo quando comparados aos sistemas tradicionais (Alves, 2000).
3. **Otimização do espaço físico:** requer até 60% menos área construída do que um armazém convencional.
4. **Melhoria na qualidade:** reduz o manuseio excessivo de mercadorias, diminuindo danos e perdas.
5. **Sustentabilidade:** minimiza o consumo energético associado à armazenagem e reduz a pegada de carbono da operação logística.

Apesar de suas vantagens, o *cross-docking* exige condições específicas para funcionar adequadamente:

- **Sincronização perfeita:** requer coordenação rigorosa entre fornecedores, transportadoras e centros de distribuição. Qualquer atraso em uma etapa pode comprometer toda a operação (Alves, 2000).
- **Alta demanda e rotatividade:** é mais indicado para produtos com volume significativo de vendas, padrões de demanda previsíveis, embalagens padronizadas e curta vida útil (no caso de perecíveis).
- **Infraestrutura adequada:** exige docas bem projetadas, sistemas de identificação automática (RFID, códigos de barras), equipamentos para movimentação rápida (esteiras, paleteiras) e sistemas integrados de informação (WMS, TMS).
- **Parcerias estratégicas:** requer relacionamento próximo com fornecedores confiáveis que cumpram rigorosamente os horários de entrega.
- **Previsão de demanda precisa:** sem um modelo confiável de previsão, o risco de gargalos operacionais aumenta consideravelmente (Bowersox et al., 2020).

No contexto dos marketplaces, o *cross-docking* tem se mostrado especialmente eficaz para:

- Produtos sazonais (ex: presentes em datas comemorativas);
- Itens promocionais (ex: Black Friday, Cyber Monday);
- Mercadorias de alta rotatividade (ex: eletrônicos e cosméticos).

Um estudo de caso da Amazon indica que a combinação de *cross-docking* com técnicas de *machine learning* para previsão de demanda pode reduzir em até 30% os custos da última milha (Rushton et al., 2022). Contudo, como alertam Lambert et al. (2021), essa estratégia não é universal — produtos com baixa demanda ou alto valor agregado podem se beneficiar mais de armazenagem convencional.

2.3 Previsão de Demanda: Métodos e Fatores Sazonais

A previsão de demanda representa um componente essencial da gestão logística eficaz, especialmente em ambientes dinâmicos e competitivos como os marketplaces. Diversas abordagens estatísticas e computacionais são utilizadas para melhorar a acurácia dessas previsões, cada uma com suas vantagens, limitações e aplicações específicas.

Fatores Sazonais e Seu Impacto

A demanda nos marketplaces é fortemente influenciada por fatores sazonais, que podem ser categorizados em:

- **Datas comemorativas:**

- *Dia das Mães* (maio): aumento médio de 40% a 60% em categorias como perfumaria, eletrônicos e artigos para o lar.
- *Dia dos Pais* (agosto): crescimento de 30% a 50% em vestuário, ferramentas e eletrônicos.
- *Natal* (dezembro): pode gerar elevação de até 300% em determinados itens, com impacto já a partir de novembro.

- **Eventos comerciais:**

- *Black Friday/Cyber Monday*: picos de 150% a 400% no volume de pedidos, exigindo preparação logística prévia.
- *Dia dos Namorados* (junho): aumento em categorias como joias, flores e produtos premium.

- **Sazonalidades regionais:**

- Férias escolares;
- Festivais e feriados locais;

- Variações climáticas periódicas.

Há uma série de desafios que devem ser considerados:

- **Efeito halo:** aumento gradual da demanda antes do evento e queda progressiva após;
- **Canibalização de vendas:** promoções de determinados produtos podem reduzir a procura por outros similares;
- **Mudanças estruturais pós-pandemia:** novos padrões de consumo e canais de compra.

Integração com as Operações Logísticas

A previsão de demanda, quando bem estruturada, oferece benefícios tangíveis para as operações logísticas, tais como:

- **Preparação de estoque** com 60 a 90 dias de antecedência;
- **Dimensionamento de frota** mais preciso, com ajuste de veículos e rotas;
- **Gestão de pessoal**, com contratação temporária para períodos de pico;
- **Negociação com fornecedores**, permitindo entregas programadas com maior eficiência.

Além desses aspectos sazonais evidentes, outros fatores, como campanhas promocionais, ações estratégicas do marketplace e mudanças no comportamento do consumidor, também afetam a demanda. Assim, o presente estudo busca aprofundar a análise desses fatores e compreender como a organização pode se preparar para tais variações, promovendo a otimização de seus processos logísticos e de distribuição.

Neste trabalho, serão aplicados dois métodos de previsão: regressão linear simples e Holt-Winters aditivo.

A regressão linear, é uma técnica paramétrica que institui uma relação linear entre uma variável dependente e uma independente, expressa pela equação $\hat{y} = \beta_0 + \beta_1x + \varepsilon$, onde β_0 e β_1 são parâmetros estimados e representam o erro aleatório (Hyndman e Athanasopoulos, 2018). Montgomery; Peck; Vining, (2021) destacam que regressão linear é um modelo clássico que é comumente utilizado por sua simplicidade de aplicação e facilidade de interpretação. Quando bem ajustado, esse modelo permite que sejam realizadas estimativas com base em dados históricos, sendo adequado em cenários de tendência contínuas. No entanto, Triola (2015) alerta que a regressão linear não apresenta sensibilidade a variações sazonais ou a comportamentos cíclicos da demanda.

A suavização exponencial foi proposta no final da década 1960 e deu início há alguns modelos de previsão que se tornaram ainda mais bem sucedidos (Brown, 1959; Holt, 1957; Winters, 1960). Para estudos que utilizem dados temporais mais complexos Winters (1960) desenvolveu o HOLT WINTERS um método com maior suavização, que ficou conhecido também como Suavização exponencial com tendência e sazonalidade. Morettin e Toloi (2018) destacam que o método não necessita de grande armazenamento de dados, é simples e pode ser facilmente automatizado. Segundo Awajan et al. (2018), o método utiliza uma função de máxima credibilidade, para estimar os padrões iniciais e prever iterativamente os parâmetros na previsão de valores futuros. Tratar (2015) destaca que as principais vantagens dos métodos da família Holt Winters são os cálculos rápidos, sensibilidade a variações sazonais e robustez.

3 Metodologia

Este estudo caracteriza-se como uma pesquisa teórico-empírica, cuja abordagem combina a fundamentação conceitual sobre gestão de demanda e operações logísticas com a análise prática de dados reais provenientes de uma organização. Trata-se de uma pesquisa de natureza aplicada, uma vez que seu principal objetivo é utilizar o conhecimento já existente sobre a relação entre a previsão de demanda e falhas operacionais com foco imediato em aplicações práticas e na melhoria dos processos logísticos.

A abordagem metodológica adotada é predominantemente quantitativa, com a aplicação de modelos de previsão baseados em regressão linear simples e no método Holt-Winter aditivo, com o intuito de estiar a demanda e comparar o desempenho preditivo por meio de diferentes abordagens.

Em relação aos objetivos, o estudo possui caráter descritivo-exploratório. Foram utilizadas fontes primárias, compostas por dados operacionais internos da organização, incluindo registros de falhas logísticas e históricos mensais de volumes entregues, coletados diretamente dos sistemas corporativos.

A pesquisa foi estruturada como um estudo de caso, tendo como objeto uma única organização do setor de logística e distribuição. A escolha por esse delineamento permitiu aprofundar a análise e contextualizar os dados dentro do ambiente específico em que os fenômenos ocorrem.

A coleta de informações foi realizada mediante observação sistemática dos registros históricos e da análise documental dos relatórios operacionais ao longo de um período de doze

meses. Essa técnica possibilitou a identificação de padrões comportamentais na demanda e suas consequências diretas sobre as operações, ressaltando a importância estratégica de uma previsão de demanda precisa para a mitigação de falhas e a otimização dos processos logísticos.

4. Estudo de Caso

4.1 Apresentação da empresa

A empresa analisada neste estudo é um *marketplace* regional que atua no Triângulo Mineiro e adota a estratégia logística de *cross-docking* em suas operações de distribuição. Esse modelo visa agilizar o fluxo de mercadorias, reduzindo significativamente a necessidade de armazenagem e promovendo maior eficiência no sistema de entregas dentro da área atendida. O objetivo final da operação é garantir que todas as entregas sejam despachadas de forma eficiente e pontual, encerrando o ciclo operacional quando os volumes são efetivamente entregues ao cliente final.

Reconhecida por sua agilidade nos prazos de entrega, a empresa depende fortemente da capacidade de antecipar variações na demanda para manter seus padrões de qualidade e desempenho logístico.

A Figura 1 apresenta o processo logístico da empresa. Pode-se verificar que a primeira atividade é o recebimento das mercadorias. Nesse momento, as cargas são descarregadas e conferidas junto aos motoristas, sendo realizada uma inspeção visual com o objetivo de identificar eventuais avarias, divergências ou problemas aparentes nas embalagens dos volumes recebidos. Os produtos que estiverem em conformidade com o processo avançam para a etapa de etiquetagem, na qual são geradas etiquetas de rota com base nos códigos de barras com informações dos pedidos presentes em cada volume.

Com as mercadorias devidamente etiquetadas, elas seguem para a etapa de classificação, onde são agrupadas de acordo com seus respectivos endereços de entrega. Após a separação dos pedidos, os volumes são encaminhados à expedição, sendo carregados nos veículos responsáveis pelas entregas.

Caso ocorra qualquer intercorrência durante a distribuição – como recusas, devoluções ou identificação de avarias – os volumes são direcionados de volta à estação. Lá, passam novamente pelo processo de inspeção e reclassificação, reiniciando o ciclo operacional.

Esse fluxo estruturado tem como principal objetivo garantir a máxima eficiência logística, padronizando as etapas e facilitando a rotina operacional.

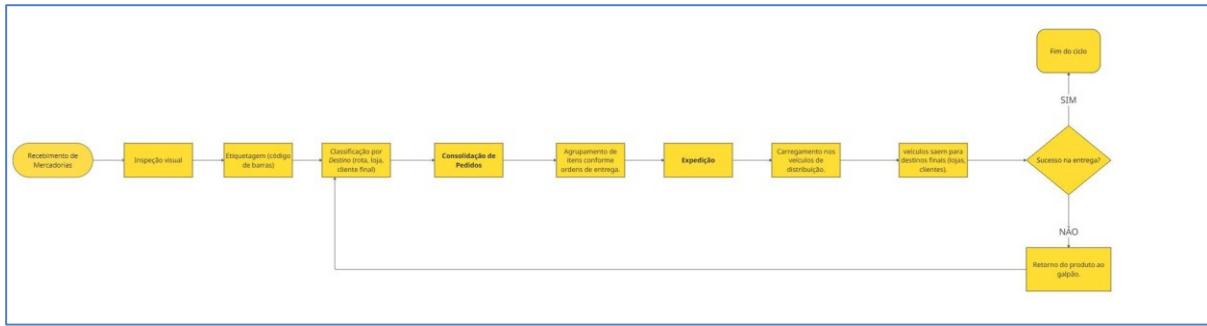


Figura 1: Fluxograma do processo logístico da empresa.

Fonte: Dados da pesquisa.

4.2 Análise da Demanda

4.2.1 A previsão de demanda realizada pela empresa

O gráfico apresentado na Figura 2 ilustra a previsão de volume (*Volume Forecast*) abrangendo o intervalo de janeiro a dezembro de 2024. Seu principal objetivo é evidenciar as tendências temporais nas variações previstas de volume, contemplando padrões de crescimento, retração e sazonalidade. O gráfico permite a identificação de picos e vales na demanda projetada, oferecendo uma perspectiva analítica sobre o comportamento logístico estimado ao longo do tempo. Observa-se que o maior volume previsto ocorreu no mês de novembro, com 432.530 unidades e o menor volume projetado foi registrado em fevereiro, com 317.991 unidades.

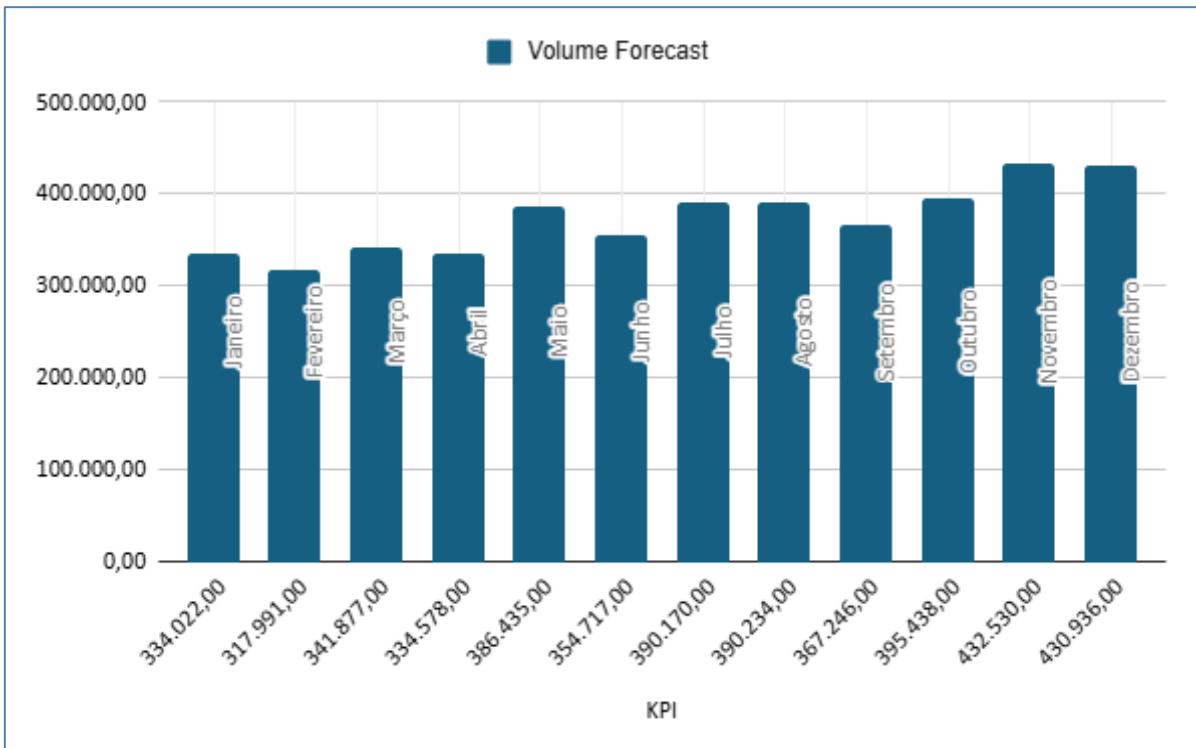


Figura 2: Previsão de volumes de janeiro a dezembro de 2024.

Fonte: Dados da pesquisa.

Os dados apresentados no gráfico de *Volume Forecast* serviram como base para o planejamento operacional da organização ao longo do ano de 2024. No contexto da previsão de demanda - seja diária, semanal, mensal e anual -, diversos fatores críticos devem ser considerados. Entre eles, destaca-se a definição da quantidade de veículos necessários para a realização das entregas, um aspecto diretamente vinculado à acurácia das estimativas de demanda. Quando esse planejamento não é conduzido de forma adequada, podem surgir gargalos operacionais relevantes, como o aumento do *backlog* diário, que representa a diferença entre o processado e o entregue. Isso afeta negativamente indicadores estratégicos monitorados pela organização.

O *Volume Forecast* refere-se às estimativas de volume de demanda projetadas pela empresa, utilizadas como referência para o planejamento de suas operações logísticas. Esses dados representam previsões quantitativas que orientam decisões estratégicas, como a alocação de recursos e a programação de entregas. Embora o modelo estatístico ou a metodologia específica aplicada para gerar essas previsões não tenha sido disponibilizado, é possível analisar a variação dos dados ao longo do tempo. Essa análise permite identificar tendências e padrões sazonais na série temporal, elementos essenciais para aprimorar a assertividade do planejamento e reduzir riscos operacionais decorrentes de estimativas imprecisas.

Adicionalmente, a previsão de demanda também subsidia a mensuração da quantidade de funcionários necessária para atender o volume esperado de unidades. Um dos desafios enfrentados pela empresa analisada é a dificuldade na captação de mão de obra qualificada, o que frequentemente a obriga a recorrer à contratação de trabalhadores por diárias, especialmente durante os períodos de pico. Essa dependência torna a operação ainda mais vulnerável a falhas de previsão, uma vez que estimativas imprecisas comprometem a alocação adequada de recursos humanos e colocam em risco tanto a eficiência quanto a continuidade do processo operacional.

4.2.2 Volumes efetivamente entregues pela empresa

O gráfico apresentado na Figura 3 ilustra o volume real de entregas (*Delivered Volume*) ao longo do mesmo período apresentado na Figura 2, compreendendo o intervalo de janeiro a dezembro de 2024.

A análise do gráfico revela alguns pontos de destaque. Observa-se uma sazonalidade significativa, com um pico acentuado no mês de dezembro, quando foram entregues 454.527 unidades. Esse aumento expressivo possivelmente está associado à elevação

da demanda em função de eventos como o Natal, a *Black Friday* e outras campanhas promocionais de final de ano. Em contrapartida, verifica-se um vale em fevereiro, com o menor volume do período - 310.687 unidades -, o que pode refletir uma retração típica no consumo pós-festividades, além de ser potencialmente influenciado pelo menor número de dias úteis neste mês.

De maneira geral, verifica-se uma tendência de crescimento gradual no volume de entregas ao longo do ano, com maior concentração de volumes no segundo semestre, especialmente entre os meses de julho e dezembro. Destaca-se ainda uma amplitude de 143.840 unidades, correspondente à diferença entre o volume máximo e o mínimo registrados, evidenciando variações significativas que reforçam a importância de estratégias logísticas adaptativas e previsões de demanda precisas.

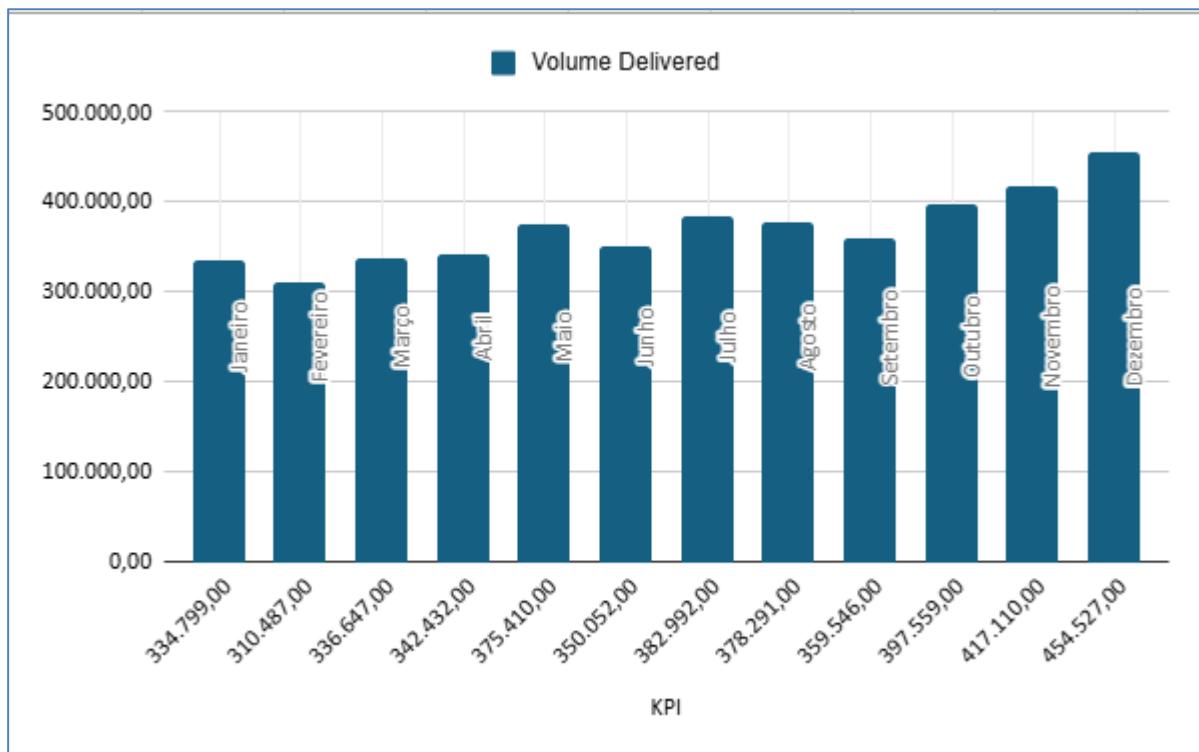


Figura 3: Volumes entregues de janeiro a dezembro de 2024.
Fonte: Dados da pesquisa.

4.2.3 Backlog

A Figura 4 apresenta os valores de *backlog* registrados entre janeiro e dezembro de 2024. Observa-se uma variação significativa ao longo do ano, com concentrações mais elevadas em meses como novembro (29.126 unidades) e agosto (24.340 unidades). Esse acúmulo indica a presença de gargalos operacionais, possivelmente associados a picos de

demandas, falhas de previsão ou restrições de capacidade de recursos, como disponibilidade limitada de veículos, equipes ou infraestrutura de apoio.

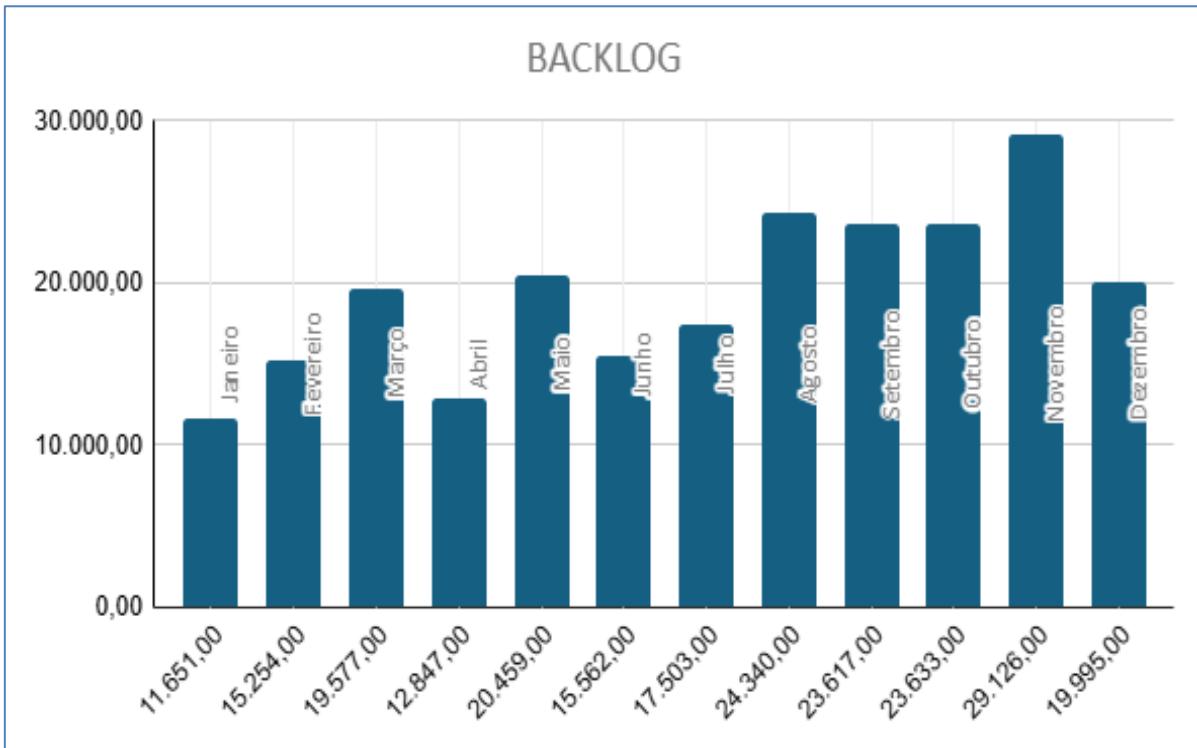


Figura 4: Volumes de *backlog* de janeiro a dezembro de 2024.

Fonte: Dados da pesquisa.

Conforme apresentado na Figura 5, percebe-se que a média anual do *backlog* em 2024 foi de 5,26%, sendo possível observar que meses como novembro (6,98%), setembro (6,57%) e agosto (6,43%) apresentaram os percentuais mais elevados, indicando maior pressão operacional nesses períodos. Nota-se que esses meses coincidem, ou estão próximos, de datas comemorativas relevantes, o que pode ser explicado pela ocorrência do chamado efeito halo - um aumento gradual da demanda impulsionado por fatores como a antecipação das compras por parte dos consumidores, motivada pelo receio de escassez de produtos ou pela possibilidade de prazos de entrega mais longos durante eventos sazonais.

Apesar do expressivo crescimento no volume de entregas em dezembro, o percentual de *backlog* manteve-se relativamente controlado, registrando 4,40%. Esse desempenho sugere a existência de um planejamento operacional eficaz para o pico de fim de ano. Tal resultado reforça o objetivo deste estudo, ao demonstrar que, mediante uma previsão antecipada do aumento da demanda, a organização foi capaz de estruturar sua operação de maneira mais robusta, minimizando as intercorrências típicas desse período crítico.

Meses	Volume Delivered	Backlog	Relação %
Janeiro	334.799	11.651	3,48%
Fevereiro	310.487	15.254	4,91%
Março	336.647	19.577	5,82%
Abril	342.432	12.847	3,75%
Maio	375.410	20.459	5,45%
Junho	350.052	15.562	4,45%
Julho	382.992	17.503	4,57%
Agosto	378.291	24.340	6,43%
Setembro	359.546	23.617	6,57%
Outubro	397.559	23.633	5,94%
Novembro	417.110	29.126	6,98%
Dezembro	454.527	19.995	4,40%
Soma	3.985.325	233.564	5,86%
Média	369.988	19.464	5,26%

Figura 5: Volumes entregues versus *backlog* de janeiro a dezembro de 2024.

Fonte: Dados da pesquisa.

4.2.4 Acurácia do modelo de previsão utilizado pela empresa

A Figura 6 apresenta uma comparação entre três variáveis logísticas ao longo dos meses de janeiro a dezembro de 2024:

- **Volume Delivered (barras azuis)**: volume efetivamente entregue.
- **Volume Forecast (linha laranja)**: volume previsto.
- **Backlog (linha preta)**: acúmulo de entregas pendentes.

Percebe-se que a linha de previsão (laranja) se mantém próxima às barras do volume real entregue durante a maior parte do ano, o que demonstra boa acurácia preditiva. Pequenas divergências são observadas em junho, agosto e dezembro, mas sem representar grandes desvios. A linha preta, que representa o *backlog*, mostra níveis relativamente baixos ao longo do ano, com picos moderados em agosto e novembro, sugerindo momentos de maior pressão sobre a capacidade operacional. Como já destacado, em dezembro, apesar do alto volume entregue, o *backlog* é um dos mais baixos.

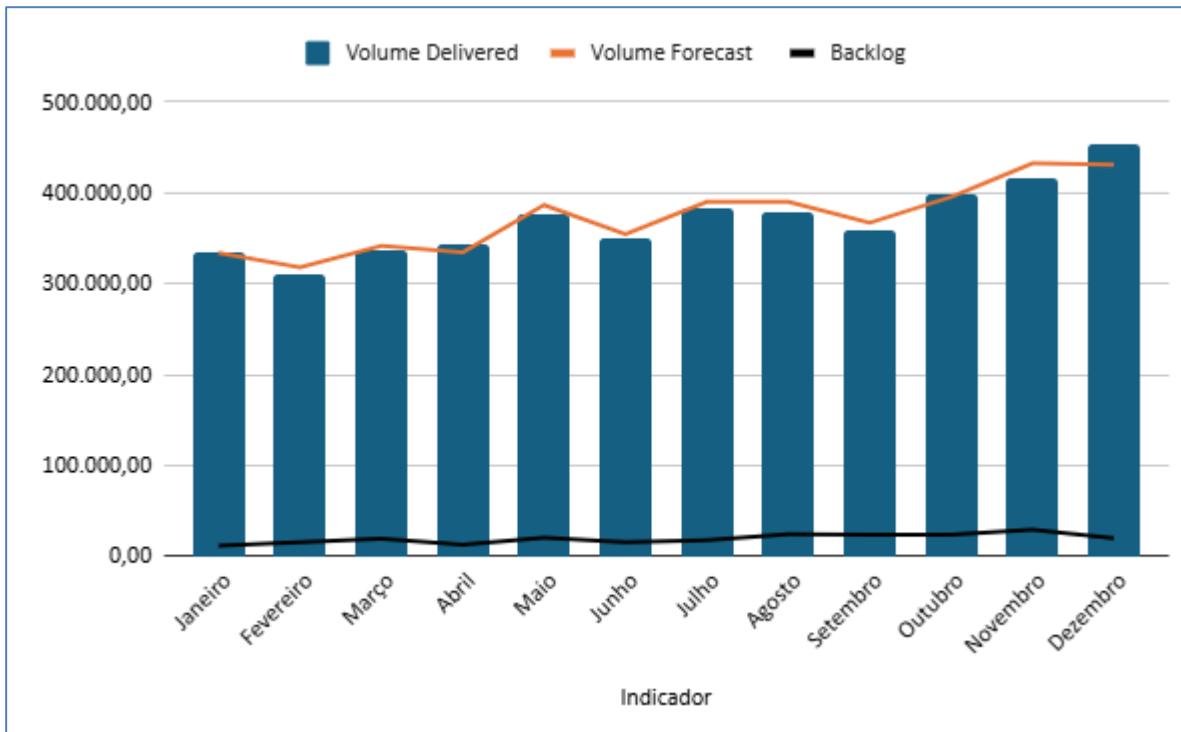


Figura 6: Volumes entregues versus Volume previsto x backlog de janeiro a dezembro de 2024.
Fonte: Dados da pesquisa.

4.2.5 Apresentação de um modelo alternativo de previsão utilizando Regressão Linear Simples

A Figura 7 apresenta uma análise de regressão linear aplicada aos dados de volume entregue (*Volume Delivered*) entre os meses de janeiro e dezembro de 2024. A linha de tendência inserida no gráfico revela um comportamento crescente ao longo do período, indicando que, de modo geral, o volume de entregas vem aumentando mês a mês. Esse padrão ascendente sugere uma consolidação gradual da demanda ao longo do ano, o que pode estar relacionado tanto ao crescimento orgânico da operação quanto à intensificação do consumo nos meses de maior apelo comercial.

A equação de regressão linear baseada no volume entregue é apresentada na Equação 1: $y = 9.895,64x + 305.666,03$

Onde:

- y é o volume entregue,
- x é o número do mês (janeiro = 1, ..., dezembro = 12),

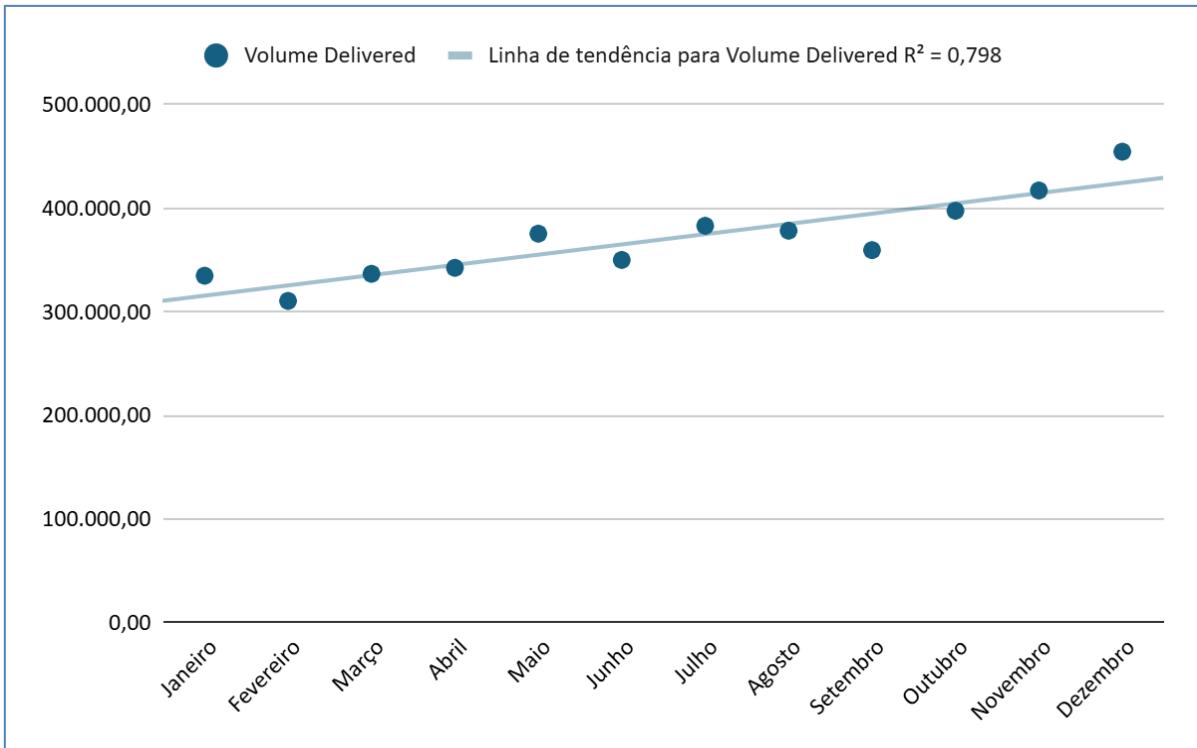


Figura 7: Evolução do Volume de Entregas com Tendência Linear – Janeiro a Dezembro de 2024
Fonte: Dados da pesquisa.

O coeficiente de determinação (R^2) da regressão é de 0,798, o que indica que aproximadamente 79,8% da variação observada no volume de entregas pode ser explicada pelo fator temporal — ou seja, pelo avanço dos meses ao longo do ano. Trata-se de um valor elevado, o que demonstra que o modelo linear se ajusta bem aos dados empíricos. Ainda que existam oscilações pontuais nos valores mensais, especialmente em alguns períodos intermediários do ano, os dados se mantêm relativamente próximos da linha de tendência, o que reforça a consistência do comportamento identificado.

A interpretação desse resultado é particularmente relevante para o planejamento logístico, pois evidencia que o crescimento na demanda não ocorre de forma aleatória, mas segue um padrão previsível. Esse padrão pode e deve ser utilizado como base para o dimensionamento de recursos operacionais, como frota, equipe e infraestrutura de suporte. Além disso, a presença de uma tendência linear bem definida contribui para a elaboração de projeções futuras, permitindo à organização antecipar-se a possíveis gargalos e ajustar sua capacidade de resposta de maneira proativa e estratégica.

É importante ressaltar que variáveis categóricas ordinais ou nominais, como meses do ano, requerem transformações específicas para sua incorporação em modelos de regressão linear, que por padrão operam com variáveis contínuas. A abordagem mais adequada envolve

a criação de variáveis dummy para representar cada categoria, garantindo que o modelo possa capturar variações não-lineares. Neste processo, uma categoria é estabelecida como baseline (ex: Janeiro=0) para evitar problemas de multicolinearidade e permitir a interpretação dos coeficientes como desvios em relação à referência. A equação do modelo passa a incluir termos do tipo β_1X_1 (Fevereiro), β_2X_2 (Março), etc., onde cada coeficiente β quantifica o efeito marginal do respectivo mês na variável dependente, controlando para demais fatores. Caso a regressão linear seja a escolha para previsão é importante levar esse tratamento em consideração.

A Figura 8 apresenta os resultados encontrados por meio da aplicação do modelo.

Meses	X	Previsão RL
Janeiro	1	315561,6667
Fevereiro	2	325457,303
Março	3	335352,9394
Abril	4	345248,5758
Maio	5	355144,2121
Junho	6	365039,8485
Julho	7	374935,4848
Agosto	8	384831,1212
Setembro	9	394726,7576
Outubro	10	404622,3939
Novembro	11	414518,0303
Dezembro	12	454.527

Figura 8: Resultados da previsão encontrada por meio da utilização de Regressão Linear Simples
Fonte: Dados da pesquisa.

4.2.6 Apresentação de um modelo alternativo de previsão utilizando Holt-Winters aditivo

Foi também aplicado o modelo de Holt-Winters aditivo à série de dados mensais de volume entregue ao longo do ano de 2024. Esse modelo, amplamente utilizado em séries temporais com tendência e sazonalidade, permite decompor a série em três componentes principais — nível, tendência e sazonalidade — e gerar previsões ajustadas com maior aderência ao comportamento histórico dos dados.

Variáveis utilizadas no modelo:

- **Nível (Lt):** o valor médio da série no tempo t , considerando a tendência e sazonalidade.

- **Tendência (T_t)**: a taxa de variação da série ao longo do tempo.
- **Sazonalidade (S_t)**: o componente repetitivo em ciclos (ex: meses).
- **Previsão (F_t)**: o valor previsto para o tempo t , usando os componentes acima.

Equação de nível

$$L_t = \alpha(Y_t - S_t - m) + (1-\alpha)(L_{t-1} + T_{t-1})$$

Onde:

α = parâmetro de suavização do nível (entre 0 e 1)

m = período da sazonalidade (ex: 12 para mensal)

Equação da Tendência:

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1}$$

Onde:

β = parâmetro de suavização da tendência

Equação da Sazonalidade:

$$S_t = \gamma(Y_t - L_t) + (1-\gamma)S_{t-m}$$

Onde:

γ = parâmetro de suavização da sazonalidade

Equação da previsão:

$$F_{t+h} = L_t + hT_t + S_t + h - m(k+1)$$

Para a implementação, os fatores de suavização (α , β e γ) foram ajustados utilizando um modelo de programação não linear no Solver do Excel, de modo a minimizar os erros de previsão, resultando em estimativas mais consistentes para os meses subsequentes. Os valores ótimos encontrados foram: (0,3874; 0,5581 e 0,3119, respectivamente).

A Figura 9 apresenta a sequência dos cálculos realizados para encontrar os valores de previsão por meio deste modelo. A previsão é a soma do Nível, da Tendência e da Sazonalidade.

Mês	Valor Real (Yt)	Nível (Lt)	Tendência (Tt)	Sazonalidade (St)	Previsão (Ft)
Janeiro	334.799,00	369.987,67	10.884,36	-35.188,67	345.683,36
Fevereiro	310.487,00	367.235,41	3.274,03	-41.913,62	328.595,81
Março	336.647,00	373.628,82	5.014,89	-40.375,28	338.268,43
Abril	342.432,00	380.256,86	5.915,16	-39.579,75	346.592,27
Maio	375.410,00	397.337,28	12.146,28	-34.073,56	375.410,00
Junho	350.052,00	399.658,75	6.663,24	-38.918,70	367.403,29
Julho	382.992,00	412.361,75	10.033,91	-35.940,18	386.455,49
Agosto	378.291,00	419.232,38	8.268,55	-37.500,16	390.000,76
Setembro	359.546,00	415.701,40	1.683,46	-43.319,14	374.065,73
Outubro	397.559,00	426.487,19	6.763,30	-38.830,29	394.420,20
Novembro	417.110,00	442.041,52	11.669,40	-34.494,96	419.215,96
Dezembro	454.527,00	467.391,98	19.304,53	-27.748,10	458.948,41

Figura 9: Resultados da previsão encontrada por meio da utilização de Holt-Winters Aditivo
Fonte: Dados da pesquisa.

4.2.7 Comparação da acuracidade do modelo de previsão da empresa e dos modelos sugeridos

Pretende-se agora comparar cada uma das abordagens apresentadas ao longo do estudo. Para isso, será calculado o desvio médio absoluto (DMA), que representa a média das diferenças absolutas entre os valores reais observados e os valores previstos. Essa métrica será aplicada a três conjuntos distintos: a previsão fornecida originalmente pela empresa, a previsão gerada por meio de regressão linear, e a previsão obtida pelo modelo de Holt-Winters. A comparação entre os resultados permite avaliar qual método apresenta menor erro e, portanto, maior capacidade de antecipar corretamente as variações na demanda. A Figura 10 apresenta o DMA para os três modelos, destacando o melhor ajuste obtido no modelo Holt-Winters

Meses	Volume Real	Previsão da empresa	DMA Empresa	Previsão RL	DMA RL	Previsão Holt-Winters	DMA Holt
Janeiro	334.799,00	334.022,00	777,00	315.561,67	19237,33333	345.683,36	10.884,36
Fevereiro	310.487,00	317.991,00	7.504,00	325.457,30	14970,30303	328.595,81	18.108,81
Março	336.647,00	341.877,00	5.230,00	335.352,94	1294,060606	338.268,43	1.621,43
Abril	342.432,00	334.578,00	7.854,00	345.248,58	2816,575758	346.592,27	4.160,27
Maio	375.410,00	386.435,00	11.025,00	355.144,21	20265,78788	375.410,00	0,00
Junho	350.052,00	354.717,00	4.665,00	365.039,85	14987,84848	367.403,29	17.351,29
Julho	382.992,00	390.170,00	7.178,00	374.935,48	8056,515152	386.455,49	3.463,49
Agosto	378.291,00	390.234,00	11.943,00	384.831,12	6540,121212	390.000,76	11.709,76
Setembro	359.546,00	367.246,00	7.700,00	394.726,76	35180,75758	374.065,73	14.519,73
Outubro	397.559,00	395.438,00	2.121,00	404.622,39	7063,393939	394.420,20	3.138,80
Novembro	417.110,00	432.530,00	15.420,00	414.518,03	2591,969697	419.215,96	2.105,96
Dezembro	454.527,00	430.936,00	23.591,00	424.413,67	30113,33333	458.948,41	4.421,41
DMA	-	-	8.750,67	-	13.593,17	-	7.623,78

Figura 10: Comparação da acuracidade dos modelos.

Fonte: Dados da pesquisa.

5 Considerações Finais

Os dados analisados evidenciam a importância da previsão de demanda como uma ferramenta essencial para o planejamento eficiente em organizações que atuam nas áreas de logística, distribuição ou produção. Por meio da análise de dados reais, foi possível comparar o desempenho de diferentes métodos preditivos, incluindo o modelo interno de previsão da empresa (Volume Forecast), a regressão linear simples e o modelo Holt-Winters aditivo.

Entre os modelos avaliados, o que apresentou melhor desempenho preditivo foi o modelo de Holt-Winters aditivo, que incorpora simultaneamente os componentes de nível, tendência e sazonalidade. Esse modelo conseguiu se aproximar com maior precisão do comportamento real da demanda, refletindo tanto a tendência geral quanto as flutuações específicas de cada mês. A superioridade do Holt-Winters foi confirmada por métricas de erro, como o desvio médio absoluto (DMA), que apontou menor divergência entre os valores previstos e os volumes efetivamente entregues, em comparação com os demais métodos.

Essa comparação reforça que, embora a regressão linear seja útil para identificar padrões de crescimento ao longo do tempo, ela não deve ser utilizada isoladamente em contextos em que a previsão de curto prazo exige sensibilidade às oscilações sazonais e promocionais. A análise também demonstra que a escolha do modelo preditivo impacta diretamente nas decisões operacionais da empresa, podendo levar a excessos de estoque ou a rupturas, como o *backlog* médio de 5,26% identificado anteriormente. Por isso, é fundamental que as previsões estejam bem alinhadas com a realidade dinâmica do negócio.

Conclui-se, portanto, que a previsão de demanda deve ser encarada como um processo contínuo, estratégico e orientado por dados históricos confiáveis, mas também flexível o suficiente para incorporar as variações de mercado. Modelos mais robustos, como o Holt-Winters, apresentam potencial superior para apoiar decisões logísticas, mitigar riscos operacionais e aumentar a eficiência da cadeia de suprimentos.

REFERÊNCIAS

- Alves, J. M. *Logística e cross-docking*. São Paulo: Atlas, 2000.
- Awajan, A. M. et al. Improved Holt-Winters method based on particle swarm optimization for forecasting seasonal data. *Journal of Computer Science*, v. 14, n. 7, p. 931-940, 2018.
- Bowersox, D. J.; Closs, D. J.; Cooper, M. B. *Supply Chain Logistics Management*. 5. ed. Nova York: McGraw-Hill, 2020.
- Brown, R. G. *Statistical forecasting for inventory control*. New York: McGraw-Hill, 1959.
- Chopra, S.; Meindl, P. *Supply Chain Management: Strategy, Planning, and Operation*. 7. ed. Nova York: Pearson, 2021.
- Christopher, M. *Logistics & Supply Chain Management*. 5. ed. Londres: Pearson, 2016.
- Christopher, M. *Logística e gerenciamento da cadeia de suprimentos: estratégias para a redução de custos e melhoria dos serviços*. 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.
- Fernie, J.; Sparks, L. *Logistics and Retail Management*. 5. ed. Londres: Kogan Page, 2019.
- Holt, C. C. Forecasting trends and seasonals by exponentially weighted moving averages. *Office of Naval Research Memorandum*, n. 52, 1957.
- Hyndman, R. J.; Athanasopoulos, G. *Forecasting: principles and practice*. 2. ed. Melbourne: OTexts, 2018.
- IBGE. *Pesquisa Anual de Comércio*. 2023.
- Kotler, P.; Kartajaya, H. *Marketing 5.0: Technology for Humanity*. Hoboken: Wiley, 2021.
- Lambert, D. M. et al. *Fundamentals of Logistics Management*. Nova York: McGraw-Hill, 2021.
- Lambert, D. M.; Stock, J. R.; Ellram, L. M. *Fundamentals of logistics management*. 2. ed. Nova York: McGraw-Hill Education, 2021.
- McKinsey & Company. *The Future of Last-Mile Delivery*. Relatório técnico, 2023.
- Montgomery, D. C.; Peck, E. A.; Vining, G. G. *Introduction to linear regression analysis*. 6. ed. Hoboken: Wiley, 2021.
- Morettin, P. A.; Toloi, C. M. C. *Análise de séries temporais*. 3. ed. São Paulo: Blucher, 2018.
- Nogueira, R. *Estratégias logísticas*. Rio de Janeiro: Elsevier, 2012.

Rushton, A. et al. *The Handbook of Logistics and Distribution Management*. 7. ed. Londres: Kogan Page, 2022.

Rushton, A.; Croucher, P.; Baker, P. *The handbook of logistics and distribution management: understanding the supply chain*. 6. ed. Londres: Kogan Page, 2022.

Tratar, L. F. Forecasting seasonal demand using Holt-Winters methods. *Organizacija*, v. 48, n. 4, p. 275-285, 2015.

Triola, M. F. *Introdução à estatística*. 11. ed. Rio de Janeiro: LTC, 2015.

Waters, D.; Rinsler, S. *Global Logistics: New Directions in Supply Chain Management*. 8. ed. Londres: Kogan Page, 2022.

Winters, P. R. Forecasting sales by exponentially weighted moving averages. *Management Science*, v. 6, n. 3, p. 324-342, 1960.