

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ADMINISTRAÇÃO, CIÊNCIAS CONTÁBEIS,
ENGENHARIA DE PRODUÇÃO E SERVIÇO SOCIAL

GABRIEL LUCAS DE MEDEIROS

PREVISÃO DE DEMANDA: APLICAÇÃO DE MÉTODOS
QUANTITATIVOS EM UMA REVENDEDORA DE
COSMÉTICOS

ITUIUTABA
2025

GABRIEL LUCAS DE MEDEIROS

**PREVISÃO DE DEMANDA: APLICAÇÃO DE MÉTODOS
QUANTITATIVOS EM UMA REVENDEDORA DE COSMÉTICOS**

Trabalho de Conclusão de Curso apresentado à Faculdade de Administração, Ciências Contábeis, Engenharia de Produção e Serviço Social da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de bacharel em Engenharia de Produção.

Orientadora: Profa. Dra. Vanessa Aparecida de Oliveira

ITUIUTABA
2025

PREVISÃO DE DEMANDA: APLICAÇÃO DE MÉTODOS QUANTITATIVOS EM UMA REVENDEDORA DE COSMÉTICOS

Trabalho de Conclusão de Curso apresentado à Faculdade de Administração, Ciências Contábeis, Engenharia de Produção e Serviço Social da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de bacharel em Engenharia de Produção.

Ituiutaba, 17 de julho de 2025.

Banca Examinadora:

Profa. Dra. Vanessa Aparecida de Oliveira (orientadora),
Universidade Federal de Uberlândia

Profa. Dra. Déborah Oliveira Almeida Carvalho,
Universidade Federal de Uberlândia

Prof. Dr. Jefferson Gomes do Nascimento,
Universidade Federal de Uberlândia

Dedico este trabalho aos meus pais, pelo estímulo,
carinho e compreensão.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me conceder força, saúde e sabedoria ao longo desta caminhada.

À minha família, por todo apoio e incentivo incondicional nos momentos mais desafiadores. Sem vocês, esta conquista não seria possível.

Ao corpo docente do curso de Engenharia de Produção, pela dedicação, ensinamentos e contribuição essencial para minha formação acadêmica e profissional.

Em especial, deixo minha gratidão à Professora Dra. Vanessa Aparecida de Oliveira, minha orientadora, por toda orientação, paciência e comprometimento durante o desenvolvimento deste trabalho.

RESUMO

O Brasil se destaca no setor de cosméticos, ocupando a 2^a posição global em lançamentos de produtos e a 4^a em consumo. Diante deste cenário, a previsão de demanda assume um papel estratégico fundamental para as empresas do setor, permitindo o alinhamento eficiente entre os diversos departamentos, otimizando a gestão de estoques, aumentando a satisfação do cliente, melhorando o desempenho logístico, equilibrando a cadeia de suprimentos e minimizando custos e desperdícios. Neste contexto, o objetivo geral deste trabalho foi aplicar métodos quantitativos de previsão de demanda em uma franquia de revenda de cosméticos para identificar o modelo com melhor desempenho preditivo, contribuindo assim para decisões estratégicas em gestão de estoques e planejamento de vendas. A metodologia empregou uma abordagem de pesquisa aplicada e quantitativa, caracterizada como um estudo de caso em uma franquia de cosméticos em Ituiutaba-MG. Os modelos quantitativos aplicados foram média móvel simples, suavização exponencial simples e decomposição da série temporal. Os principais resultados revelaram que, para o produto sabonete, o modelo de decomposição da série temporal apresentou o menor Desvio Absoluto Médio ($MAD = 15,55$), enquanto a média móvel simples com $n=4$ obteve o menor Erro Percentual Absoluto Médio ($MAPE = 18,94\%$). Contudo, a decomposição foi considerada mais adequada devido à sua robustez teórica e capacidade de incorporar explicitamente a sazonalidade e a tendência da demanda. Para o desodorante, o modelo de decomposição da série temporal também demonstrou o melhor desempenho, com o menor MAD (14,13) e um $MAPE$ de 30,37%, próximo ao da suavização exponencial simples ($\alpha=0,2$ com 30,31%), mas com um MAD superior para esta última.

Palavras-chave: previsão de demanda; séries temporais; média móvel; suavização exponencial simples; decomposição de série temporal.

ABSTRACT

Brazil stands out in the cosmetics sector, ranking 2nd globally in product launches and 4th in consumption. In this context, demand forecasting assumes a fundamentally strategic role for companies in the sector, enabling efficient alignment among different departments, optimizing inventory management, increasing customer satisfaction, improving logistics performance, balancing the supply chain, and minimizing costs and waste. Given this scenario, the general objective of this study was to apply quantitative demand forecasting methods in a cosmetics resale franchise to identify the model with the best predictive performance, thus contributing to strategic decision-making in inventory management and sales planning. The methodology employed an applied and quantitative research approach, characterized as a case study conducted in a cosmetics franchise in Ituiutaba, Minas Gerais, Brazil. The quantitative models applied were simple moving average, simple exponential smoothing, and time series decomposition. The main results revealed that, for the soap product, the time series decomposition model presented the lowest Mean Absolute Deviation (MAD = 15.55), while the simple moving average with n=4 achieved the lowest Mean Absolute Percentage Error (MAPE = 18.94%). However, decomposition was considered more suitable due to its theoretical robustness and ability to explicitly incorporate seasonality and demand trends. For the intimate deodorant, the time series decomposition model also showed the best performance, with the lowest MAD (14.13) and a MAPE of 30.37%, close to that of simple exponential smoothing ($\alpha = 0.2$ with 30.31%), but with a higher MAD for the latter.

Keywords: demand forecasting; time series; moving average; simple exponential smoothing; time series decomposition.

LISTA DE FIGURAS

Figura 1	Padrões de série temporal de demanda.....	5
Figura 2	Séries temporais do sabonete e desodorante íntimos.....	12
Figura 3	Aplicação da média móvel simples, para o sabonete.....	14
Figura 4	Aplicação da média móvel simples, para o desodorante.....	14
Figura 5	Aplicação da suavização exponencial simples, para o sabonete.....	16
Figura 6	Aplicação da suavização exponencial simples, para o desodorante.....	16
Figura 7	Aplicação da decomposição de série temporal, para o sabonete.....	20
Figura 8	Aplicação da decomposição de série temporal, para o desodorante.....	20
Figura 9	Monitoramento do modelo de decomposição, para o sabonete.....	23
Figura 10	Monitoração do modelo de decomposição, para o desodorante.....	23

LISTA DE TABELAS

Tabela 1	Definição dos modelos matemáticos e seus respectivos parâmetros.....	13
Tabela 2	Valores de erro de previsão para a média móvel simples.....	15
Tabela 3	Valores de erro de previsão para a suavização exponencial simples.....	17
Tabela 4	Decomposição da série temporal do sabonete.....	19
Tabela 5	Valores de erro de previsão para a decomposição de série temporal.....	21
Tabela 6	Erros de previsão a partir dos modelos aplicados.....	22

SUMÁRIO

1 INTRODUÇÃO	1
1.1 CONTEXTUALIZAÇÃO	1
1.2 OBJETIVOS DE PESQUISA.....	1
1.2.1 <i>Objetivo geral</i>	2
1.2.2 <i>Objetivos específicos</i>	2
1.3 JUSTIFICATIVA.....	2
2 FUNDAMENTAÇÃO TEÓRICA.....	3
2.1 PREVISÃO DE DEMANDA	4
2.2 MÉTODOS QUANTITATIVOS DE PREVISÃO DE DEMANDA	5
2.2.1 <i>Média móvel simples</i>	6
2.2.2 <i>Suavização exponencial simples</i>	6
2.2.3 <i>Suavização da série temporal</i>	7
2.3 ERROS DE PREVISÃO	8
3 METODOLOGIA.....	10
4 RESULTADOS E DISCUSSÃO	11
4.1 CARACTERIZAÇÃO DA EMPRESA	11
4.2 ANÁLISE DAS SÉRIES TEMPORAIS E DEFINIÇÃO DOS MODELOS DE PREVISÃO.....	11
4.3 APLICAÇÃO DO MODELO DA MÉDIA MÓVEL SIMPLES	13
4.4 APLICAÇÃO DO MODELO DA SUAVIZAÇÃO EXPOENCIAL SIMPLES	15
4.5 APLICAÇÃO DO MODELO DA DECOMPOSIÇÃO DE SÉRIE TEMPORAL	18
4.6 COMPARAÇÃO E VALIDAÇÃO DOS MODELOS DE PREVISÃO	21
5 CONSIDERAÇÕES FINAIS	25
REFERÊNCIAS	26

1. INTRODUÇÃO

1.1. Contextualização

De acordo com dados da Associação Brasileira da Indústria de Higiene Pessoal, Perfumaria e Cosméticos (Abihpec), o Brasil ocupa a 2^a posição entre os países que mais lançam produtos na área e está em 4º lugar entre os países que mais consomem produtos de beleza no mundo. Segundo um relatório especial da McKinsey, a previsão é que o setor atinja o faturamento de U\$ 580 bilhões até 2027 (SEBRAE, 2023).

Diante desse cenário, as empresas do setor de cosméticos têm investido cada vez mais em inovação, tanto na melhoria de produtos já existentes quanto no desenvolvimento de novos itens para atender às demandas do mercado. Nesse contexto, a previsão de demanda assume papel estratégico, configurando-se como uma das responsabilidades mais relevantes das equipes de planejamento. Quando bem estruturada, essa previsão permite o alinhamento eficiente entre os diversos setores da organização, promovendo maior integração e assertividade nas tomadas de decisão. De acordo com Turbino (2007), a previsão de demanda é a operação crucial tanto para o planejamento estratégico da produção quanto para os departamentos de vendas e finanças de todas as empresas.

A previsão de demanda é fundamentada, em grande parte, na análise dos dados históricos de vendas de produtos ou serviços da empresa, permitindo uma correlação direta com os demais setores organizacionais. Um dos setores mais impactados por essa previsão é a gestão de estoques, que depende diretamente da acurácia dessas estimativas para otimizar seus processos. Sua importância se reflete em diversas áreas organizacionais, ao proporcionar ganhos expressivos em eficiência operacional, aumento da satisfação do cliente, melhoria do desempenho logístico e maior equilíbrio na cadeia de suprimentos. A previsão de demanda contribui, ainda, para a minimização de custos e redução de desperdícios, ao viabilizar o alinhamento entre oferta e demanda (Pellegrini e Fogliatto 2001).

Os métodos de previsão podem ser classificados em qualitativos, quantitativos ou híbridos. Segundo Stevenson (2001), os métodos quantitativos requerem uma sequência consistente de observações históricas e se baseiam em modelos matemáticos para estimar a demanda futura. Elsayed e Boucher (1994) destacam que tais modelos visam projetar valores futuros com base em séries temporais. Por outro lado, a abordagem qualitativa é construída a partir de informações subjetivas, como opiniões de especialistas, julgamentos e experiências

individuais, sendo especialmente útil em contextos com pouca disponibilidade de dados históricos (Tubino, 2007).

Dante dessas considerações, apresentam-se a seguir os objetivos do presente trabalho.

1. 2. Objetivos

1. 2. 1. Objetivo geral

Aplicar métodos quantitativos de previsão de demanda em uma franquia de revenda de cosméticos, com o propósito de identificar aquele que apresenta o melhor desempenho preditivo, contribuindo para a tomada de decisões estratégicas relacionadas à gestão de estoques e ao planejamento de vendas.

1.2.2. Objetivos específicos

- Identificar os produtos de maior demanda;
- Realizar o levantamento dos dados históricos de demanda;
- Analisar a série temporal e definir os modelos matemáticos;
- Aplicar e validar os modelos quantitativos.

1.3. Justificativa

Uma das principais dificuldades associadas ao uso de previsões na tomada de decisão está na escolha apropriada dos métodos de geração de previsões com base na análise do comportamento de séries temporais. A seleção inadequada pode comprometer a acurácia das estimativas e, consequentemente, afetar negativamente o planejamento operacional da empresa. Nesse sentido, pesquisas que se concentram na avaliação comparativa de diferentes métodos preditivos revelam-se altamente relevantes, pois contribuem para a definição de abordagens mais eficazes conforme as características específicas da demanda (Makridakis et al., 1998).

Ao identificar o método mais adequado para determinada situação, é possível obter previsões mais precisas, o que permite um planejamento mais assertivo das operações, desde a área comercial até os processos de reposição e pedidos de produtos. Dessa forma, a adoção de modelos preditivos bem fundamentados oferece suporte estratégico à tomada de decisão, aumentando a eficiência da capacidade de resposta da empresa às demandas do mercado (Stevenson, 2018).

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Previsão de demanda

Toda organização necessita do dimensionamento das suas capacidades produtivas, isto é, atender da melhor maneira suas demandas, evitando o desperdício de tempo, material, energia ou a falta de produtos para atender seus respectivos clientes (Spadotto, 2024). Nesse ponto, a previsão de demanda surge como forma de atender a esse interesse. Dessa forma, ela consiste na análise de dados passados com o objetivo de estimar, de forma sistemática, as necessidades futuras de uma organização. A sua utilização se relaciona com a necessidade crescente de melhoria nos processos internos, visto que compreende etapas diversas desde a aplicação no planejamento das ações e decisões gerenciais, até à disponibilidade de produtos na quantidade, qualidade e momento adequados (Moreira, 2008).

No mesmo sentido, o conhecimento prévio da quantidade de produtos ou serviços que a organização pretende comercializar constitui uma base importante para grande parte das decisões organizacionais, sejam elas estratégicas, táticas ou operacionais (Moreira, 2008). É importante destacar, que independente de qual setor de atuação da respectiva organização, a previsão de demanda é uma atividade em comum entre elas. Nestes cenários, a previsão de demanda é um método para o quanto se pretende vender os produtos ou serviços no futuro, sendo um processo racional de busca de informações acerca do valor das vendas futuras de um produto ou serviço (Salgado et al., 2022). Segundo Kotler (1998), na maioria dos mercados, a demanda da empresa não é estável e uma boa previsão de demanda torna-se essencial.

A eficácia da previsão depende do cumprimento de etapas essenciais, sendo elas: a definição clara do objetivo da previsão, o número de itens a considerar, o nível de agregação desejado, o horizonte de planejamento, os recursos disponíveis e o grau de detalhamento necessário (Lustosa et al., 2008).

Existem vários métodos de previsão, cujo quais podem ser utilizados em várias situações distintas, porém são dependentes de alguns fatores. Os principais fatores a serem explorados são a disponibilidade de dados, tempo e recursos, haja visto que os métodos que utilizam os modelos matemáticos exigem abundância dos dados e, para além disso, profissionais capacitados. O outro fator apontado é o horizonte de previsão, devido a existência de métodos que se adequam melhor para previsões de longo prazo, e outros que são direcionados para previsões rotineiras, ou seja, de curto prazo (Lopes, 2014).

Nesse contexto, destacam-se dois grupos de métodos de previsão de demanda: qualitativos e quantitativos. Os métodos qualitativos baseiam-se em estimativas subjetivas, muitas vezes formuladas com base na opinião de consumidores ou especialistas. Apesar de flexíveis e úteis em situações de escassez de dados históricos, esses métodos podem apresentar viés interpretativo. O resultado do modelo empregado depende das demandas previstas no horizonte do tempo, por isso devem ser acompanhadas para se verificar se as hipóteses iniciais se confirmam ou não (Lustosa et al., 2008).

Casonatto (2017) reafirma que os métodos qualitativos consideram o conhecimento e a experiência de especialistas, bem como compreende as percepções de vendedores, compradores e gestores. Em razão da sua natureza subjetiva, podem ser interpretados como julgamentos intuitivos e, por consequência, tendem a ser considerados abstratos, em contraste com os métodos quantitativos, que se baseiam em dados concretos e modelos formais (Silva, 2020).

2.2. Métodos quantitativos de previsão de demanda

A previsão de demanda por meio de métodos quantitativos é baseada na reprodução de padrões identificados na análise da série de caráter temporal de demanda, que passarão a ser entendidas como históricas (Pellegrini e Fogliatto 2001).

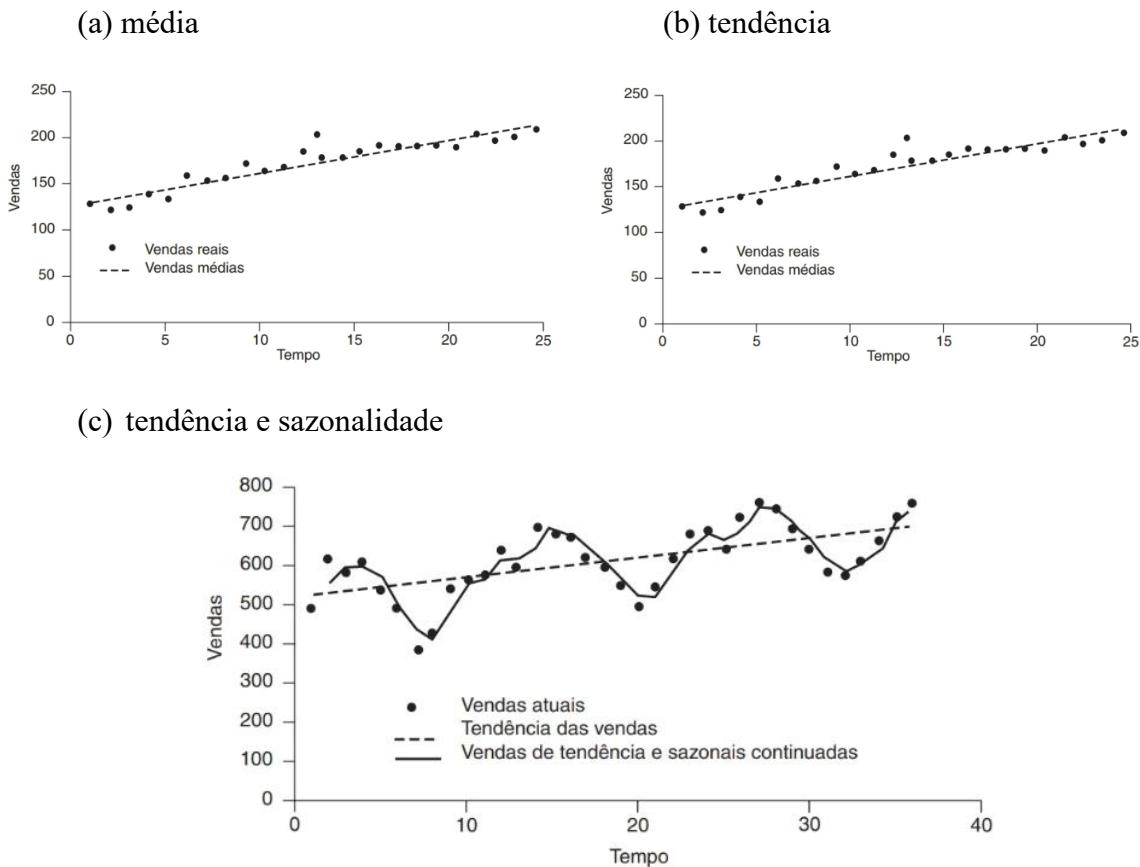
Higuchi (2006), afirma que os métodos quantitativos consistem em uma abordagem imparcial na análise de informações históricas, com o objetivo de fazer previsões futuras por meio do uso de modelos matemáticos e estatísticos. As projeções de demanda utilizando métodos quantitativos são alcançadas ao replicar os padrões identificados durante a análise da série temporal de demanda. Também se consideram as variáveis preditoras e descrevem fatores que influenciam as várias de interesse (Veitos, 2023). Ademais, por sua característica objetiva e imparcial, permite que as previsões sejam adaptáveis às mudanças do ambiente devido ao conhecimento atualizado dos especialistas (Santos, 2023). Na próxima etapa do trabalho, serão abordados os métodos de previsão que se fundamentam em séries temporais.

De forma geral, as séries temporais podem ser descritas como uma sequência de dados históricos provenientes de um mesmo objeto de análise, que são descritos em um determinado período. As previsões fundamentadas em séries temporais partem do princípio de que a demanda futura se trata de uma projeção dos valores passados, não sofrendo influências de variáveis. Destaca-se, ainda, que se trata de um método simples e usual de previsão e, quando bem empregado, resulta em bons resultados (Andrade, 2017).

Fernandes e Godinho Filho (2010) destacam que uma série temporal é composta por um conjunto de dados organizados cronologicamente e que pode apresentar as seguintes características principais (Figura 1a-c):

- Média: ocorre quando os dados da série flutuam entre uma média constante;
- Tendência: ocorre quando uma série é analisada por um longo período de tempo, e apresenta um comportamento ascendente ou descendente.
- Sazonalidade: ocorre quando há um padrão cíclico de mudança em um intervalo de tempo fixo, seja em um dia, uma semana, um mês ou uma estação;

Figura 1 – Padrões de série temporal de demanda



Fonte: Ballou (2006)

Para Lustosa (2008), caso haja movimentos consideráveis de tendência ou sazonalidade, é possível aplicar diferentes métodos, como o método de Holt para dados apenas com tendência, ou os modelos de Holt-Winters e a decomposição da série temporal para dados com tendência e/ou sazonalidade. Quando a série temporal dos dados coletados não apresenta um movimento de tendência significativo, é possível utilizar métodos como média móvel e suavização exponencial simples.

2.2.1. Média móvel simples

Segundo Tubino (2007), os modelos baseados em médias são úteis para reduzir as variações aleatórias nos dados históricos, e suavizam os valores extremos ao proporcionar uma previsão com menor variabilidade. No caso da média móvel, são utilizados dados de um conjunto de períodos mais recentes, com um número definido previamente, para gerar a previsão. A cada inclusão de um novo período no conjunto, um período mais antigo é removido. A Eq. (1) apresenta o cálculo da média móvel simples.

$$M_t = \frac{\sum_{i=1}^t D_t}{t} \quad \text{Eq. (1)}$$

Sendo: M_t = média móvel de t períodos; D_t = demanda no período t ; t = número de períodos; i = índice do período ($i = 2, 3, 4, \dots$).

2.2.2. Suavização exponencial simples

De acordo Ballou (2006), o método de suavização exponencial simples é especialmente indicado para demandas sem tendência ou sazonalidade. Essa técnica é conhecida por fornecer resultados precisos em comparação a outros modelos e possui uma capacidade notável de se adaptar facilmente a mudanças. Conforme Fernandes e Godinho Filho (2010), esse método envolve o uso de pesos, ou coeficientes de suavização (α), que diminuem de forma geométrica ou exponencial à medida que os dados retrocedem. Esse coeficiente deve assumir valores que variam entre 0 e 1, sendo modificado pelo previsor.

O coeficiente de suavização (α) representa o grau de sensibilidade do modelo às variações recentes da demanda. Quando o valor de α está mais próximo de 1, o modelo dá maior peso às observações mais recentes, tornando-se mais responsivo a mudanças repentinas no padrão da demanda. Por outro lado, quando α se aproxima de 0, o modelo dá maior peso às observações passadas, produzindo uma previsão mais estável e menos sensível a flutuações recentes. Assim, a escolha adequada de α permite ao tomador de decisão ajustar o modelo conforme o comportamento específico da série temporal analisada, equilibrando estabilidade e sensibilidade. Em aplicações práticas, o valor ideal de α pode ser determinado com base em testes de desempenho, utilizando métricas de erro como desvio médio absoluto (MAD), com o objetivo de identificar a configuração que proporcione a maior acurácia preditiva (Tubino, 2007).

A Eq. (2) apresenta o cálculo da média móvel simples.

$$F_t = F_{t-1} + \alpha (D_{t-1} - F_{t-1}) \quad \text{Eq. (2)}$$

Sendo: F_t = previsão para o período t ; F_{t-1} = previsão para o período $t - 1$; α = coeficiente de suavização; D_{t-1} = demanda do período $t - 1$.

2.2.3. Decomposição da série temporal

De acordo com Ballou (2006), a decomposição clássica é amplamente aceita por sua robustez metodológica e elevada precisão preditiva. A decomposição de séries temporais parte do princípio de que os dados observados apresentam padrões identificáveis, os quais podem ser decompostos em componentes distintos com o objetivo de facilitar a compreensão do comportamento da demanda ao longo do tempo. A identificação e análise desses componentes permite não apenas a interpretação mais precisa da série, mas também a geração de projeções futuras com maior acurácia. Entre os principais componentes extraídos por meio dos métodos de decomposição estão: a tendência, que representa as variações de longo prazo no nível médio da série, e a sazonalidade, que corresponde a padrões sistemáticos de flutuação em intervalos regulares, como semanas, meses ou trimestres.

Um dos métodos mais utilizados para projeções em séries que apresentam simultaneamente tendência e sazonalidade é a decomposição clássica, conforme descrito por Lustosa et al. (2008). Esse método permite modelar os dados a partir da separação dos componentes sazonais e tende a proporcionar previsões mais ajustadas à realidade. O fator sazonal, dentro dessa abordagem, pode ser tratado de duas formas distintas: aditiva ou multiplicativa.

Conforme descrito por Stevenson (2001), no modelo aditivo, a sazonalidade é incorporada por meio da adição (ou subtração) de uma constante à média da série, sendo apropriado para séries cujas variações sazonais se mantêm constantes ao longo do tempo. Já o modelo multiplicativo supõe que a influência sazonal varia proporcionalmente ao nível da série, sendo aplicada por meio da multiplicação da média por um fator percentual correspondente ao padrão sazonal. A escolha entre os modelos aditivo e multiplicativo depende da natureza da variabilidade da série, sendo essencial para garantir a fidelidade das projeções.

A escolha entre o modelo aditivo e o modelo multiplicativo depende da forma como a sazonalidade e os demais componentes interagem com o nível da série. O modelo aditivo é mais

adequado quando os efeitos sazonais e de tendência são constantes ao longo do tempo e independentes da magnitude da série. Já o modelo multiplicativo é indicado quando esses efeitos variam proporcionalmente ao nível da demanda, sendo mais comum em séries que apresentam crescimento ou declínio ao longo do tempo.

Segundo Moreira (2008), os dois modelos podem ser representados pelas Eq. (3) e (4), respectivamente.

$$F = (T_t) + (S_t) + (E_t) \quad \text{Eq. (3)}$$

$$F = (T_t) \times (S_t) \times (E_t) \quad \text{Eq. (4)}$$

Sendo: F = valor da série (demanda prevista); T_t = componente de tendência do período t ; S_t = componente de sazonalidade do período t ; E_t = componente do erro no período t .

2.3. Erros de previsão

O erro está presente em toda previsão de demanda e, por isso, deve ser mensurado, uma vez que a magnitude do erro indica se o modelo de previsão adotado é adequado ou não, com base na proximidade entre os valores previstos e os valores reais (Silva, 2020).

Segundo Tubino (2009), é fundamental reconhecer que cada técnica de previsão de demanda possui uma aplicação específica, não existindo um método universal que se aplique a todas as situações. O autor ressalta, ainda, a importância de monitorar continuamente o desempenho dos modelos utilizados, realizando ajustes e atualizações conforme necessário, de modo a garantir maior precisão nas estimativas.

Fernandes e Godinho Filho (2010) reforçam que, embora as previsões frequentemente apresentem algum grau de erro, esse pode ser minimizado com a escolha adequada do método e o ajuste correto dos parâmetros. De forma semelhante, Neto (2023) aponta que erros de previsão podem decorrer tanto da seleção inadequada do modelo quanto da imprevisibilidade do ambiente de mercado, o que exige atenção redobrada na análise do comportamento da demanda.

Nesse contexto, Lustosa et al. (2008) enfatizam que existem diversas formas de mensurar os erros de previsão, sendo uma das abordagens mais comuns a comparação direta entre os valores reais observados e os valores previstos, conforme Eq. (5). Essa análise permite avaliar o desempenho do modelo adotado e implementar melhorias contínuas no processo de previsão.

$$E_t = D_t - F_{t-1} \quad \text{Eq. (5)}$$

Sendo: E_t = erro de previsão no período t ; D_t = demanda real para o período t ; F_{t-1} = demanda prevista para o período $t - 1$.

Entre as principais métricas utilizadas para avaliar a acurácia das previsões, destaca-se o Desvio Absoluto Médio (*MAD – Mean Absolute Deviation*), cuja função é mensurar o erro médio entre os valores previstos e os valores reais observados, desconsiderando o sinal do erro (positivo ou negativo). O MAD é calculado a partir da média dos valores absolutos das diferenças entre a demanda real e a demanda prevista, oferecendo uma medida intuitiva da precisão do modelo. Idealmente, quanto mais próximo de zero for o valor do MAD, maior será a acurácia da previsão.

Essa métrica é especialmente útil por não ser influenciada por compensações entre erros positivos e negativos. No entanto, valores muito pequenos de erro médio absoluto podem, às vezes, mascarar grandes desvios individuais que se anulam mutuamente. A Eq. (6) expressa o cálculo do MAD:

$$MAD = \frac{\sum_{t=1}^n |D_t - F_t|}{n} \quad \text{Eq. (6)}$$

Sendo:

n = número total de períodos considerados; D_t = demanda real para o período t ; F_t = demanda prevista para o período t .

Além do MAD, é comum o uso de outras métricas complementares, como o Erro Percentual Absoluto Médio (*MAPE – Mean Absolute Percentage Error*), que permitem análises adicionais sobre o comportamento dos erros, considerando a variabilidade e a proporcionalidade dos desvios (Eq. 7).

$$EPAM = \frac{1}{n} \sum_{t=1}^n \frac{|D_t - F_t|}{|D_t|} * 100 \quad \text{Eq. (7)}$$

3. METODOLOGIA

Há duas categorias principais para classificar as pesquisas: básicas e aplicadas. Para (Gil, 2010), a pesquisa aplicada visa resolver problemas na sociedade em que os pesquisadores vivem, enquanto a pesquisa básica busca preencher lacunas no conhecimento. Nesse sentido, o estudo atual é classificado como pesquisa aplicada, pois tem o objetivo de solucionar problemas práticos e imediatos.

No que diz respeito ao problema de pesquisa, ele é categorizado como quantitativo devido à utilização de modelos matemáticos para calcular a previsão de demanda. Através dos resultados obtidos, busca-se demonstrar a importância do tema. Quanto aos objetivos do estudo atual, trata-se de uma pesquisa descritiva. Para Gergardt e Silveira (2009), o procedimento metodológico engloba a seleção dos tipos de pesquisa, técnicas de coleta e análise de dados, além da especificação das etapas e procedimentos adotados em cada uma delas. No persente trabalho foi realizado um estudo de caso em uma franquia de cosméticos situada em Ituiutaba-MG, onde foi feito o levantamento da demanda histórica de produtos, a fim de aplicar técnicas quantitativas de previsão de demanda.

A técnica de coleta de dados aplicada foi por meio de entrevista semiestruturadas com a proprietária do negócio para levantar em que aspecto a empresa tinha maior necessidade de melhorias. Após a realização desse levantamento, posteriormente foi requisitado ao setor financeiro o histórico de vendas dos produtos de maior demanda da empresa, conforme indicado pelo proprietário. Estes dados foram disponibilizados por meio de planilhas no Excel, sendo as séries temporais relativas ao período de junho de 2021 a maio de 2023.

Após realizar a coleta dos dados, estes foram organizados, filtrados e apresentados graficamente para realizar a análise da série temporal. Em seguida, foram escolhidos os modelos de previsão apropriados. As previsões foram realizadas utilizando o software Excel.

4. RESULTADOS

4.1. Caracterização da empresa

A empresa analisada neste estudo trata-se de uma franquia de pequeno porte do setor de cosméticos e bem-estar, localizada no Triângulo Mineiro, no estado de Minas Gerais. Com mais de 15 anos de atuação na cidade e uma trajetória consolidada de 37 anos no mercado, a franquia oferece uma variedade de produtos distribuídos em diversas categorias, incluindo cuidados capilares, produtos para o lar, higiene pessoal, maquiagem, perfumaria, saúde e bem-estar, atendendo tanto ao público masculino quanto feminino.

Destaca-se que as vendas são direcionadas, principalmente, para clientes cadastrados na loja, os quais compram os produtos com desconto e os revendem pelo preço regular do portfólio mensal, obtendo assim uma comissão sobre as vendas. Além desse público, há também consumidores que optam por não se cadastrar, adquirindo os produtos pelo valor integral para uso próprio ou outros fins.

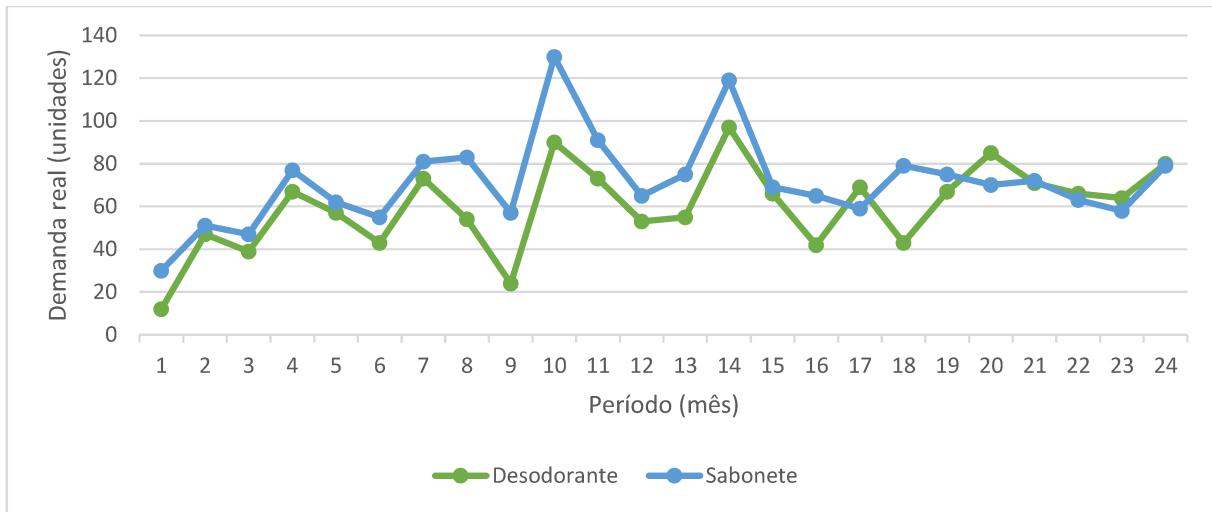
Com base nas entrevistas realizadas com a proprietária, constatou-se que a linha de produtos íntimos apresenta a maior demanda, configurando-se como o principal segmento comercial da empresa. Dentre os itens que compõem essa linha, destacam-se o sabonete e o desodorante íntimo, que, juntos, correspondem a aproximadamente 85% das vendas desse segmento, evidenciando seu expressivo volume de comercialização.

Nesse contexto, realizou-se a previsão de demanda com o objetivo de subsidiar o ajuste das estratégias de vendas. Para isso, foram aplicadas técnicas quantitativas baseadas em séries temporais, cujos resultados, referentes à estimativa da demanda dos produtos selecionados, são apresentados a seguir.

4.2. Análise das séries temporais e definição dos modelos de previsão

A Figura 2 apresenta as séries temporais referentes aos dois produtos analisados. O período inicial considerado no estudo corresponde a junho de 2021, enquanto o período 24 representa o mês de maio de 2023, totalizando uma série temporal de 24 meses.

Figura 2 – Séries temporais do sabonete e desodorante íntimos



Fonte: Autor (2025)

A partir da Figura 2, observa-se inicialmente que as séries de demanda dos dois produtos seguem um comportamento similar ao longo do tempo, sugerindo uma possível correlação entre elas. Essa relação pode ser explicada pelo padrão de consumo observado na prática: frequentemente, os clientes adquirem os dois produtos de forma conjunta, ou seja, quem compra o sabonete íntimo tende a adquirir também o desodorante íntimo. Apesar dessa relação, a demanda do sabonete é consistentemente superior, o que pode ser atribuído à sua menor durabilidade em comparação ao desodorante, exigindo reposições mais frequentes por parte das clientes. Essa dinâmica reforça a necessidade de planejamento de demanda integrado para ambos os itens, a fim de evitar rupturas no estoque e garantir a satisfação do consumidor.

Além disso, nota-se que ambas as séries apresentam uma tendência inicial de crescimento nos primeiros dez meses do período analisado, reflexo de uma fase de expansão da empresa nesse período, que resultou em aumento na base de clientes. A partir desse momento, as demandas assumem um comportamento mais regular, indicando possível fase de estabilização do consumo.

Observam-se ainda picos acentuados de demanda nos períodos 10 (março/2022) e 14 (julho/2022) para ambos os produtos. Esse comportamento pode ser atribuído às estratégias promocionais que foram lançadas pela proprietária nesses meses, as quais exerceram influência direta sobre o aumento no consumo desses itens.

Em termos de variação individual, o sabonete apresenta oscilações mais amplas entre os períodos 1 e 15, enquanto o desodorante exibe variações mais frequentes e abruptas ao longo dos períodos 1 a 18, porém com menor amplitude. Por exemplo, é possível identificar

momentos de alta seguidos por quedas abruptas, como a queda significativa entre os períodos 8 e 9 (de aproximadamente 83 para 57 unidades, para o sabonete, e de 54 para 24 unidades, para o desodorante) e uma subida igualmente abrupta entre os períodos 9 e 10 (de 25 para 90 unidades, para o sabonete, e de 57 para 120 unidades, para o desodorante). De acordo com informações fornecidas pela proprietária, esse padrão de demanda pode ser atribuído ao comportamento de parte das clientes, que optavam por adquirir volumes maiores em uma única compra. Como consequência, o intervalo entre as reposições se tornava mais longo, gerando oscilações mais marcantes no registro mensal da demanda.

Nos períodos finais da série, observa-se uma aproximação entre as curvas de demanda dos dois produtos, acompanhada por menores amplitudes de oscilação. Esse comportamento sugere uma convergência no padrão de consumo, decorrente de ajustes nos níveis de oferta e na implementação de ações promocionais por parte da empresa, contribuindo para uma maior estabilidade nas vendas.

A partir das análises das séries temporais dos dois produtos, foram selecionados três modelos matemáticos para a realização das previsões de demanda, conforme apresentado na Tabela 1.

Tabela 1 – Definição dos modelos matemáticos e seus respectivos parâmetros

Modelo matemático	Parâmetros
Média móvel simples	$n = 2 / 3 / 4$
Suavização exponencial simples	$\alpha = 0,2 / 0,5 / 0,8$
Decomposição da série temporal	Ciclo sazonal = 12 meses

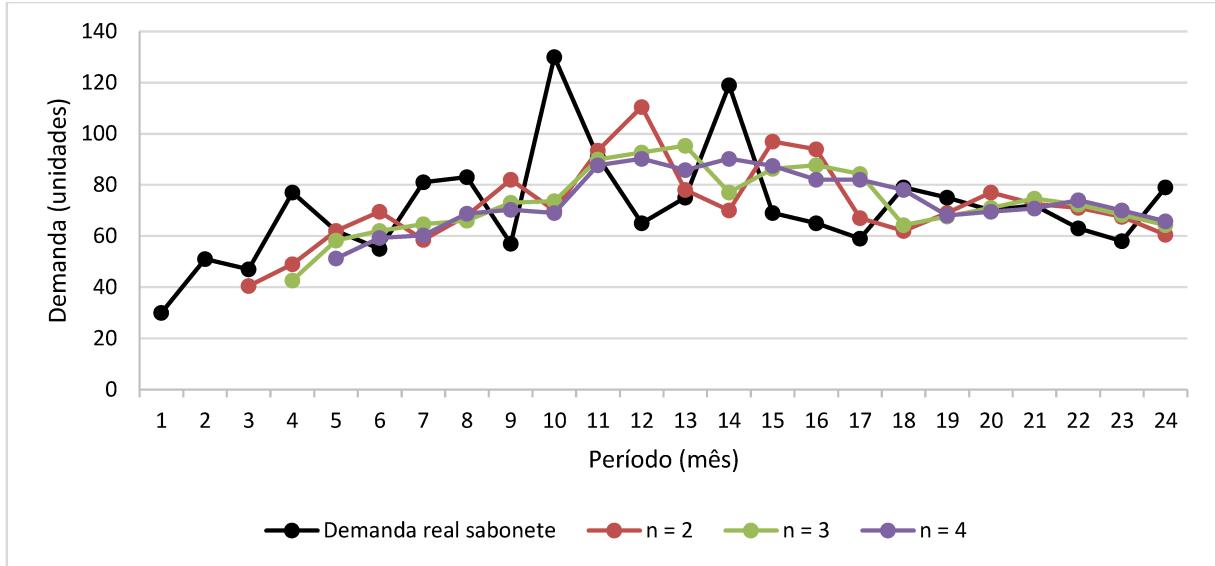
Fonte: Autor (2025)

A seguir, são apresentados os resultados obtidos com a aplicação dos modelos de previsão para cada um dos produtos analisados. Em sequência, são comparados os indicadores de desempenho MAD e MAPE, com o objetivo de identificar o modelo que forneceu as previsões mais precisas. Por fim, é apresentado o gráfico de controle baseado em 4 MAD, permitindo o monitoramento da aderência entre os valores previstos e os valores reais.

4.3. Aplicação do modelo da média móvel simples

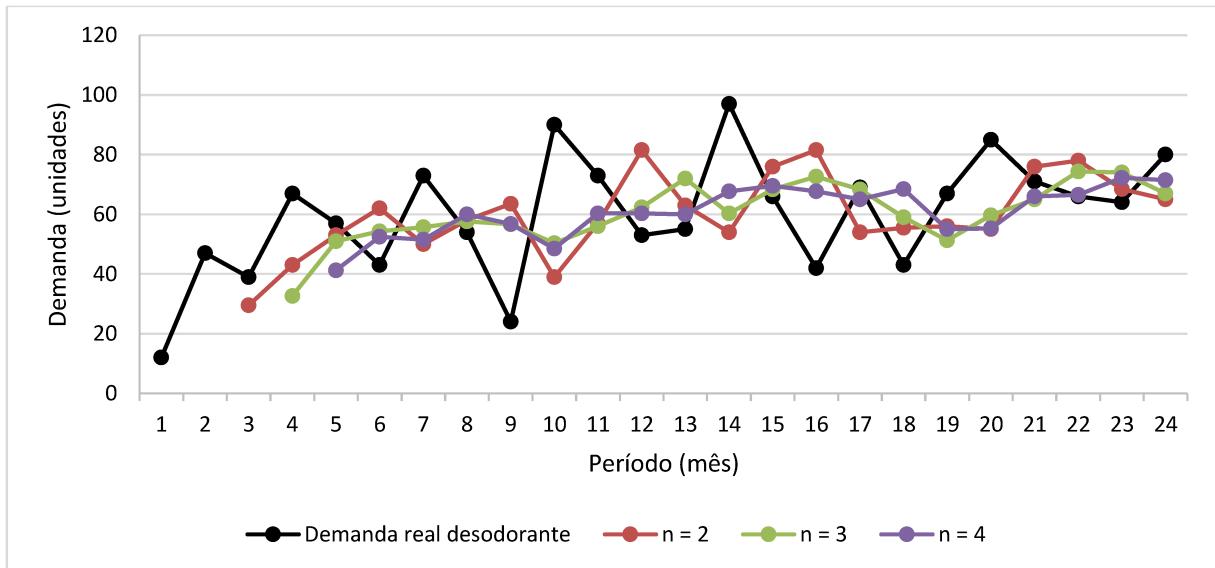
A Figuras 3 e 4 apresentam a previsão de demanda pela aplicação do modelo da média móvel simples, com n igual a 2, 3 e 4, para os produtos sabonete e desodorante, respectivamente.

Figura 3 – Aplicação da média móvel simples, para o sabonete



Fonte: Autor (2025)

Figura 4 – Aplicação da média móvel simples, para o desodorante



Fonte: Autor (2025)

Na Figura 3 e 4, observa-se que todas as médias móveis acompanharam de forma razoável o comportamento da demanda real ao longo do tempo, com maior sensibilidade às variações nos valores de n menores. A média móvel com $n = 2$ se mostrou mais reativa às oscilações, refletindo com mais precisão os picos e quedas da série real, especialmente nos períodos de maior instabilidade (como entre os períodos 9 e 14). Em contrapartida, as médias com $n = 3$ e

$n = 4$ apresentaram maior suavidade, sendo mais eficazes na captura da tendência geral, mas com menor aderência às variações bruscas.

Em ambos os casos, a escolha do melhor valor de n depende do objetivo da previsão. Valores menores são indicados quando se deseja maior sensibilidade às variações recentes, enquanto valores maiores são preferíveis quando se busca reduzir o impacto de oscilações pontuais, favorecendo a estabilidade da estimativa. Os resultados obtidos servem de base para a próxima etapa da análise, que envolve a avaliação da precisão dos modelos por meio dos indicadores MAD e MAPE, apresentados na Tabela 2.

Tabela 2 – Valores de erro de previsão para a média móvel simples

Parâmetro	Sabonete	Desodorante
$n = 2$	MAD = 18,72 MAPE = 23,72%	MAD = 19,27 MAPE = 34,95%
$n = 3$	MAD = 17,48 MAPE = 22,33%	MAD = 17,81 MAPE = 29,97%
$n = 4$	MAD = 15,84 MAPE = 18,94%	MAD = 15,96 MAPE = 27,96%

Fonte: Autor (2025)

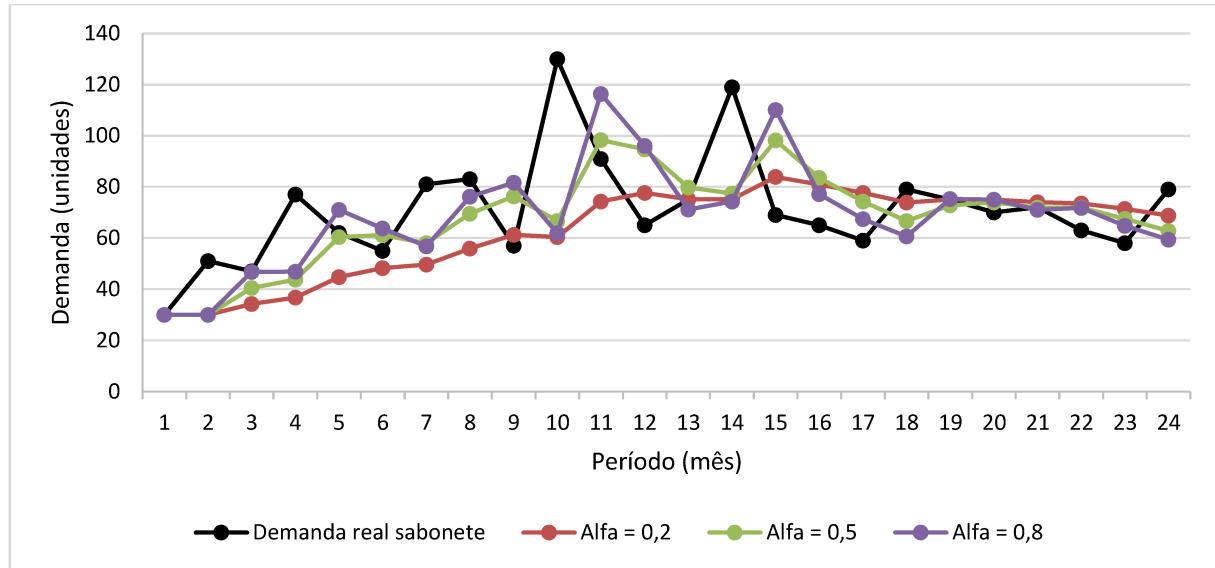
Para ambos os produtos, observa-se uma redução progressiva nos valores de MAD e MAPE à medida que o parâmetro n aumenta, o que indica melhoria na acurácia das previsões. Tanto para o sabonete quanto para o desodorante, o modelo com $n = 4$ apresentou o melhor desempenho. O valor de MAD indica que, em média, a previsão diferiu da demanda real em aproximadamente 16 unidades, enquanto o MAPE mostra que o erro percentual médio em relação à demanda observada foi de 18,94%, para o produto sabonete ($n = 4$).

Esses resultados confirmam que, para ambos os produtos, a média móvel simples com média móvel de 4 períodos proporciona previsões mais estáveis e com menor erro médio absoluto e percentual.

4.4. Aplicação do modelo na suavização exponencial simples

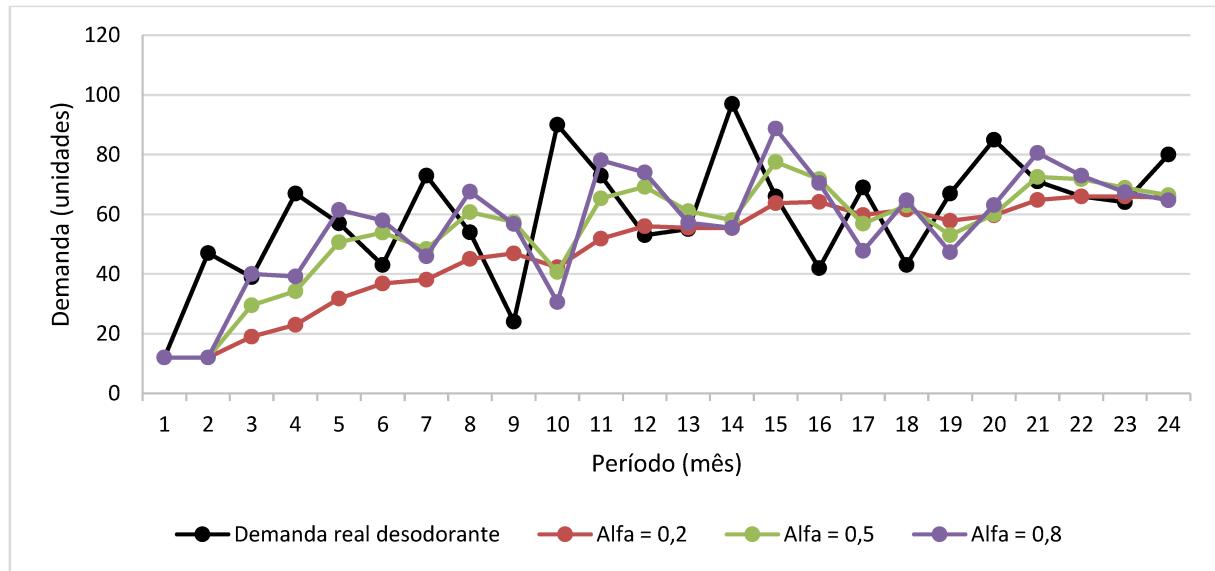
As Figuras 5 e 6 ilustram a aplicação da suavização exponencial simples na previsão da demanda dos produtos sabonete e desodorante íntimos, respectivamente, para valores de α igual a 0,2, 0,5 e 0,8.

Figura 5 – Aplicação da suavização exponencial simples, para o sabonete



Fonte: Autor (2025)

Figura 6 – Aplicação da suavização exponencial simples, para o desodorante



Fonte: Autor (2025)

Na Figura 5, referente ao sabonete, nota-se que o modelo com $\alpha = 0,2$ apresenta uma curva mais suavizada, com menor aderência às oscilações pontuais da série real. Isso indica uma maior ênfase nos valores passados, tornando o modelo mais conservador e menos influenciado por variações recentes. Em contrapartida, o modelo com $\alpha = 0,8$ se mostra mais sensível às mudanças na demanda, aproximando-se com maior fidelidade dos picos e quedas observados, especialmente entre os períodos 9 e 14. O modelo com $\alpha = 0,5$ oferece um

equilíbrio entre suavização e capacidade de resposta, acompanhando razoavelmente as flutuações sem ser excessivamente volátil. Na Figura 6, referente ao desodorante, observa-se padrão semelhante.

De modo geral, a escolha do valor de α impacta diretamente a sensibilidade do modelo às variações recentes. Quanto maior o alfa, maior o peso dado aos dados mais recentes e, consequentemente, maior a reatividade da previsão. Assim, a definição do parâmetro ideal será guiada pela análise dos erros de previsão apresentados na Tabela 3, com o objetivo de identificar o valor de α mais preciso para cada produto.

Tabela 3 – Valores de erro de previsão para a suavização exponencial simples

Parâmetro	Sabonete	Desodorante
$\alpha = 0,2$	MAD = 17,65 MAPE = 21,46%	MAD = 18,52 MAPE = 30,31%
$n = 0,5$	MAD = 16,14 MAPE = 21,10%	MAD = 17,31 MAPE = 31,42%
$n = 0,8$	MAD = 17,48 MAPE = 22,44%	MAD = 19,04 MAPE = 33,60%

Fonte: Autor (2025)

Ao analisar a Tabela 3, observa-se que a demanda por sabonete apresenta valores significativos de MAPE mais baixos do que a demanda por desodorante em todas as configurações de parâmetros testadas. Essa diferença sugere que a demanda por sabonete é, de modo geral, mais fácil de prever com maior precisão utilizando o modelo da suavização exponencial simples, em comparação com a demanda por desodorante. Este resultado corrobora a observação prévia na análise das demandas a partir da Figura 2, segundo a qual o desodorante apresenta maior frequência de oscilações ao longo da série temporal. Tal comportamento influencia diretamente a precisão das previsões, uma vez que séries com maior variabilidade tendem a gerar maior erro nos modelos preditivos.

Em relação ao desempenho dos parâmetros para cada produto, para a demanda de sabonete, o melhor desempenho de previsão, caracterizado pelo menor erro, foi alcançado com o parâmetro $\alpha = 0,5$. Os outros parâmetros testados apresentaram erros ligeiramente superiores para este produto. Para a demanda de desodorante, o parâmetro $\alpha = 0,2$ gerou o menor MAPE (30,31%), acompanhado de um MAD de 18.

4.5. Aplicação do modelo da decomposição de série temporal

A seguir, apresenta-se o procedimento detalhado para a previsão de demanda do produto sabonete, utilizando o método de decomposição da série temporal com modelo multiplicativo e ciclo sazonal de 12 meses. Esse método permite separar a série observada em três componentes principais: tendência, sazonalidade e componente aleatória (residual), possibilitando uma previsão mais precisa ao recombinar os efeitos sistemáticos identificados.

A Tabela 4 apresenta os resultados da decomposição da série temporal do sabonete, evidenciando os valores da demanda real, os componentes extraídos e a demanda estimada obtida a partir da recomposição dos fatores de tendência e sazonalidade. O detalhamento dos cálculos é apresentado apenas para este produto, considerando que o procedimento adotado para o desodorante é o mesmo, diferenciando-se apenas pelos valores observados da demanda.

A primeira coluna, “Período”, representa a sequência cronológica dos meses analisados, de 1 a 24, correspondendo a dois anos completos de observação. Em seguida, a coluna “Demanda” exibe os valores reais registrados de vendas mensais do produto.

A coluna “Índice Sazonal” apresenta os índices sazonais corrigidos, obtidos previamente por meio da aplicação da média móvel centrada e ajustados para um ciclo completo de 12 meses. Esses índices quantificam a influência da sazonalidade sobre a demanda em cada mês do ano, indicando se determinado período apresenta comportamento acima ou abaixo da média anual. Esses índices são essenciais para remover o efeito da sazonalidade na etapa de dessazonalização da série e, posteriormente, para recompor a previsão ajustada à realidade de cada mês.

Valores superiores a 1 sinalizam meses com demanda sazonalmente elevada em relação à média. Por exemplo, o período 10 (mês de março) apresenta um índice de 1,6346, o que indica que a demanda nesse mês tende a ser aproximadamente 63% maior do que a média mensal anual. Em contrapartida, valores inferiores a 1 indicam meses de menor demanda sazonal. É o caso do período 1 (mês de junho), com índice 0,8684, o que significa que, historicamente, a demanda nesse mês é cerca de 13% inferior à média mensal do ano.

A coluna “Série Dessaazonalizada” apresenta os valores dessazonalizados, obtidos pela divisão da demanda real pelo respectivo índice sazonal. Esse procedimento remove o efeito da sazonalidade, permitindo a análise da tendência isoladamente.

A partir desses valores, foi ajustada uma reta de tendência pela técnica dos mínimos quadrados, cuja equação obtida a partir dos dados dessazonalizados é: $y = 0,7536x + 64,255$. A coluna “Tendência” contém os valores gerados por essa equação, representando a componente de longo prazo da série.

A seguir, a coluna “Série sem Tendência” mostra os valores obtidos pela remoção da tendência, por meio da divisão da demanda real pela tendência estimada. Essa etapa evidencia as flutuações aleatórias não explicadas pelos efeitos sistemáticos da série. Com base na recomposição da tendência e da sazonalidade, foi possível gerar as previsões de demanda, registradas na coluna “Previsão”, que representa o valor estimado para cada período.

As colunas finais avaliam o desempenho do modelo. A coluna “Erro” representa a diferença entre o valor real observado e o valor previsto para cada período. A seguir, a coluna “Erro Absoluto” apresenta o módulo dessa diferença, ou seja, o desvio sem considerar o sinal. Esses valores servem de base para o cálculo do MAD, que expressa, em unidades, a média dos erros absolutos. Por fim, a coluna “Erro Percentual Absoluto” indica o erro expresso em termos percentuais em relação à demanda real de cada período. A média desses valores resulta no MAPE, utilizado para avaliar a precisão do modelo de forma relativa.

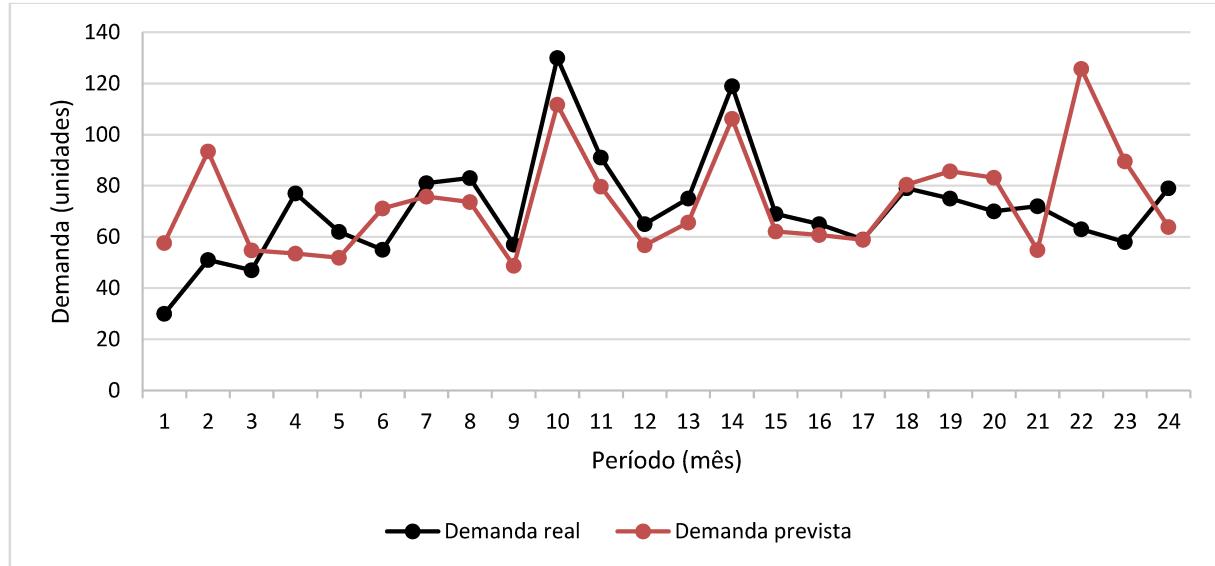
Tabela 4 – Decomposição da série temporal do sabonete

Período	Demand	Índice Sazonal	Série Dessaazona-lizada	Tendência	Série sem Tendência	Previsão	Erro	Erro Absoluto	Erro Percentual Absoluto
1	30	0,8864	33,85	65,01	0,46	57,62	-27,62	27,62	0,92
2	51	1,4203	35,91	65,76	0,78	93,40	-42,40	42,40	0,83
3	47	0,8227	57,13	66,52	0,71	54,72	-7,72	7,72	0,16
4	77	0,7965	96,67	67,27	1,14	53,58	23,42	23,42	0,30
5	62	0,7638	81,17	68,02	0,91	51,96	10,04	10,04	0,16
6	55	1,0338	53,20	68,78	0,80	71,10	-16,10	16,10	0,29
7	81	1,0905	74,28	69,53	1,16	75,82	5,18	5,18	0,06
8	83	1,0479	79,21	70,28	1,18	73,65	9,35	9,35	0,11
9	57	0,6857	83,13	71,04	0,80	48,71	8,29	8,29	0,15
10	130	1,5556	83,57	71,79	1,81	111,68	18,32	18,32	0,14
11	91	1,0975	82,91	72,54	1,25	79,62	11,38	11,38	0,13
12	65	0,7754	83,83	73,30	0,89	56,83	8,17	8,17	0,13
13	75	0,8864	84,62	74,05	1,01	65,64	9,36	9,36	0,12
14	119	1,4203	83,79	74,81	1,59	106,24	12,76	12,76	0,11
15	69	0,8227	83,87	75,56	0,91	62,16	6,84	6,84	0,10
16	65	0,7965	81,61	76,31	0,85	60,78	4,22	4,22	0,06
17	59	0,7638	77,24	77,07	0,77	58,86	0,14	0,14	0,00
18	79	1,0338	76,42	77,82	1,02	80,45	-1,45	1,45	0,02
19	75	1,0905	68,78	78,57	0,95	85,68	-10,68	10,68	0,14
20	70	1,0479	66,80	79,33	0,88	83,13	-13,13	13,13	0,19
21	72	0,6857	105,01	80,08	0,90	54,91	17,09	17,09	0,24
22	63	1,5556	40,50	80,83	0,78	125,75	-62,75	62,75	1,00
23	58	1,0975	52,85	81,59	0,71	89,54	-31,54	31,54	0,54
24	79	0,7754	101,89	82,34	0,96	63,85	15,15	15,15	0,19

Fonte: Autor (2025)

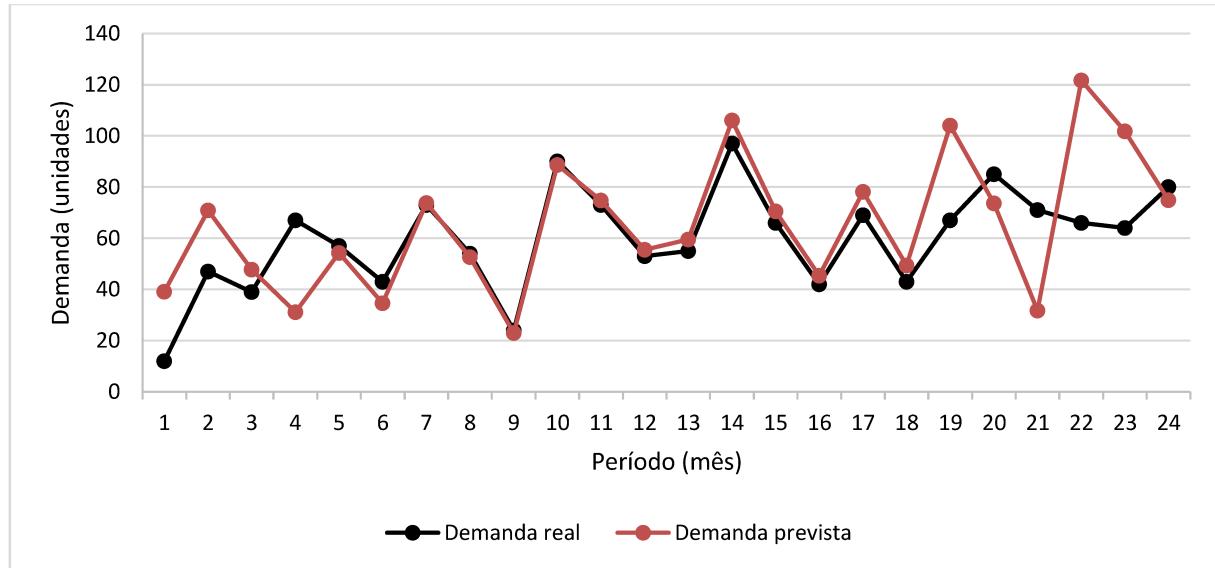
As Figuras 7 e 8 apresentam os gráficos que mostram o comportamento da demanda real em comparação com a demanda prevista para os dois produtos analisados, permitindo visualizar o grau de aderência entre os valores observados e estimados ao longo do tempo.

Figura 7 – Aplicação da decomposição de série temporal, para o sabonete



Fonte: Autor (2025)

Figura 8 – Aplicação da decomposição de série temporal, para o desodorante



Fonte: Autor (2025)

Nas Figuras 7 e 8, de modo geral, observa-se que para ambos os produtos a curva da demanda prevista acompanha com boa aderência o comportamento da série real, especialmente

nos períodos centrais da série, onde a estimativa da tendência se apresenta mais robusta. Isso indica que o modelo foi capaz de captar adequadamente os padrões sazonais e de tendência, reduzindo o erro entre valores observados e estimados.

No entanto, nota-se que em alguns períodos, principalmente nos extremos da série (início e final), ocorrem desvios mais acentuados entre os valores reais e previstos. Tal comportamento é esperado, uma vez que o cálculo da tendência por média móvel centrada demanda observações anteriores e posteriores ao ponto em análise, o que afeta a acurácia das estimativas nos limites da série.

Considerando o desempenho da decomposição da série temporal para cada produto, observa-se na Tabela 5 que, para a demanda de sabonete, o modelo resultou em um MAD de 15,55 e MAPE de 25,44%, o que indica um desempenho razoável em termos de precisão, com erro percentual moderado. Para o produto desodorante, os resultados demonstraram um MAD ligeiramente inferior, de 14,13, porém acompanhado de um MAPE superior, de 30,37%, o que revela uma maior dispersão percentual dos erros em relação aos valores reais de demanda. Esses resultados refletem a maior variabilidade observada na série do desodorante, que impacta diretamente a acurácia percentual do modelo.

Tabela 5 – Valores de erro de previsão para a decomposição de série temporal

Parâmetro	Sabonete	Desodorante
Ciclo sazonal = 12	MAD = 15,55 MAPE = 25,44%	MAD = 14,13 MAPE = 30,37%

Fonte: Autor (2025)

4.6. Comparação e validação dos modelos de previsão

A Tabela 6 apresenta os índices de erro de previsão resultantes da aplicação dos diferentes modelos de previsão de demanda para os dois produtos analisados.

Tabela 6 – Erros de previsão a partir dos modelos aplicados

Modelo	Parâmetro	Sabonete	Desodorante
Média móvel simples	n = 2	MAD = 18,72 MAPE = 23,72%	MAD = 19,27 MAPE = 34,95%
	n = 3	MAD = 17,48 MAPE = 22,33%	MAD = 17,81 MAPE = 29,97%
	n = 4	MAD = 15,84 MAPE = 18,94%	MAD = 15,96 MAPE = 27,96%
Suavização exponencial simples	$\alpha = 0,2$	MAD = 17,65 MAPE = 21,46%	MAD = 18,52 MAPE = 30,31%
	$\alpha = 0,5$	MAD = 16,14 MAPE = 21,10%	MAD = 17,31 MAPE = 31,42%
	$\alpha = 0,8$	MAD = 17,48 MAPE = 22,44%	MAD = 19,04 MAPE = 33,60%
Decomposição	Ciclo sazonal = 12	MAD = 15,55 MAPE = 25,44%	MAD = 14,13 MAPE = 30,37%

Fonte: Autor (2025)

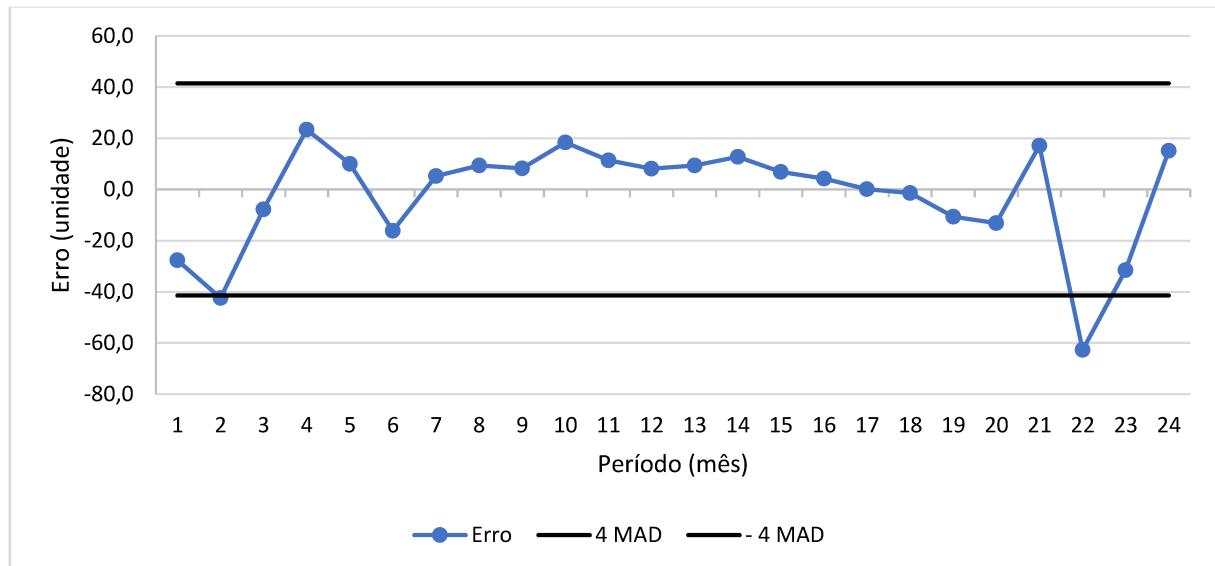
Com base nos resultados apresentados na Tabela 6, é possível realizar uma análise comparativa entre os modelos de previsão para os dois produtos analisados. Para o produto sabonete, o menor MAD (15,55) foi obtido com o modelo de decomposição da série temporal, o que indica uma menor discrepância média entre os valores previstos e os valores reais. Em relação ao MAPE, que mede a precisão percentual da previsão, o melhor desempenho foi alcançado pela média móvel simples com n = 4, apresentando 18,94%, inferior aos 25,44% obtidos pelo modelo de decomposição.

Apesar disso, o desempenho do modelo de decomposição apresenta vantagens importantes, uma vez que se trata de um modelo mais completo, que incorpora sazonalidade de maneira explícita e permite projeções mais fundamentadas para séries com padrões cílicos. Nesse contexto, o aumento no MAPE é compensado pela capacidade do modelo de representar estruturas sazonais reais da demanda. Portanto, para o sabonete, o modelo decomposição se mostra o mais adequado, especialmente considerando sua maior robustez teórica.

No caso do desodorante, o modelo de decomposição também se destacou, apresentando o menor MAD (14,13), o que o torna o modelo com melhor desempenho em termos de erro médio. Em relação ao MAPE, o valor registrado (30,37%) é muito próximo daquele obtido com a suavização exponencial simples com $\alpha = 0,2$ (30,31%), que, por sua vez, apresentou um MAD superior (18,52). Dado esse contexto, o modelo de decomposição também se mostra mais acurado para o desodorante.

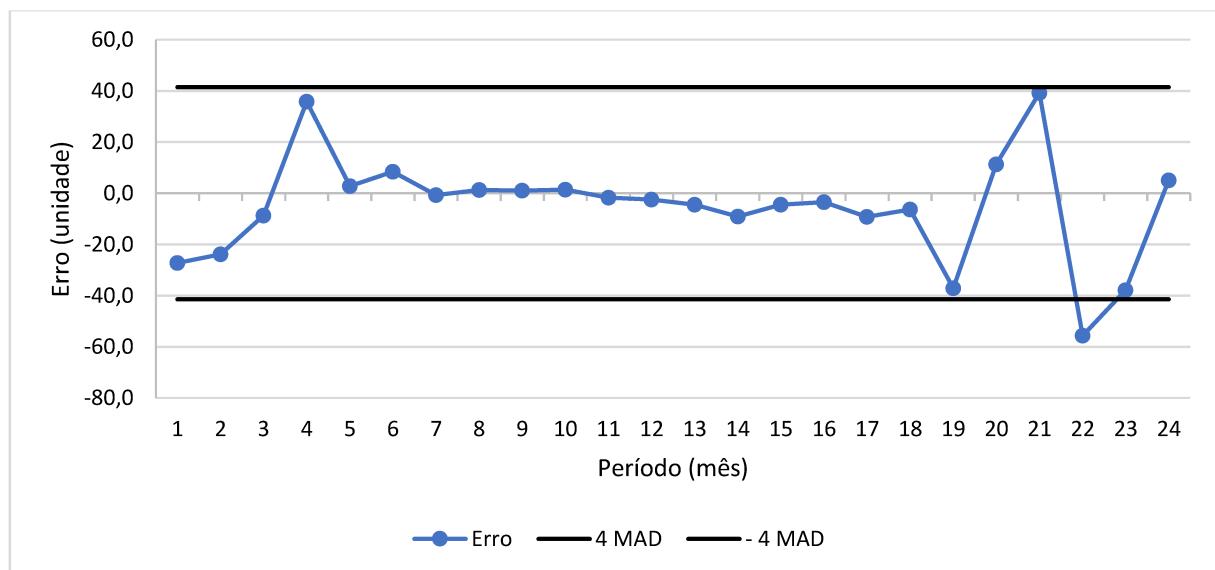
As Figuras 9 e 10 apresentam os gráficos de controle utilizados para monitorar os erros do modelo de decomposição da série temporal aplicado à demanda dos produtos. O gráfico é construído com base no conceito do 4 MAD, que estabelece os limites superior e inferior de controle. Esse parâmetro avalia a estabilidade do modelo de previsão. Erros que permanecem dentro desses limites indicam um desempenho consistente e confiável do modelo, enquanto pontos fora dos limites podem sinalizar *outliers* na demanda ou falhas no ajuste do modelo.

Figura 9 – Monitoramento do modelo de decomposição, para o sabonete



Fonte: Autor (2025)

Figura 10 – Monitoração do modelo de decomposição, para o desodorante



Fonte: Autor (2023)

A análise dos gráficos de controle por 4 MAD, apresentados nas Figuras 9 e 10, evidencia que, para ambos os produtos, os erros de previsão gerados pelo modelo de decomposição da série temporal se mantiveram, em sua maioria, dentro dos limites de controle estabelecidos (± 4 MAD). Embora se observe que os dois produtos apresentaram um ponto com erro abaixo do limite inferior no período 22, os modelos mostram-se estáveis e consistentes, sugerindo que não há evidência de desvios sistemáticos ou rupturas no padrão de erro.

5. CONSIDERAÇÕES FINAIS

Este estudo demonstrou a importância da previsão de demanda para a gestão de uma franquia de cosméticos, destacando seu papel fundamental na organização eficiente dos processos internos da empresa. A capacidade de antecipar as necessidades dos clientes permite otimizar o estoque, reduzir perdas, evitar rupturas de produtos essenciais e garantir que os itens mais procurados estejam sempre disponíveis, melhorando a experiência de compra e fortalecendo a fidelização dos consumidores.

No cenário altamente competitivo do setor de cosméticos, a aplicação de métodos de previsão de demanda tornou-se uma ferramenta indispensável para a administração empresarial. A previsibilidade no comportamento das vendas possibilita uma gestão mais estratégica, auxiliando na tomada de decisões que impactam diretamente o desempenho financeiro da franquia. Além disso, uma projeção de demanda bem estruturada contribui para a redução de desperdícios, a otimização dos custos operacionais e a maximização dos lucros, fatores essenciais para garantir a sustentabilidade e o crescimento do negócio no longo prazo.

Dessa forma, este trabalho analisou diferentes métodos de previsão de demanda com o objetivo de identificar aquele que melhor se adapta ao comportamento das séries históricas de vendas da franquia de cosméticos situada em Ituiutaba-MG. Foram exploradas metodologias como a média móvel simples, a suavização exponencial simples e a decomposição clássica, avaliando seu desempenho na projeção da demanda com base nos valores de MAD e MAPE. A análise desses modelos permitiu compreender padrões sazonais, variações na demanda ao longo do tempo e tendências que influenciam diretamente o abastecimento da loja.

Os resultados obtidos foram satisfatórios, comprovando a eficácia das técnicas analisadas e atingindo o objetivo de identificar o método mais apropriado para prever a demanda na franquia. A implementação de uma metodologia precisa de previsão contribui significativamente para a gestão do estoque, evitando excessos ou escassez de produtos, além de facilitar o planejamento de compras e o mapeamento dos itens mais estratégicos para ações promocionais, permitindo que a franquia desenvolva campanhas de descontos e ofertas sazonais com base na demanda real dos clientes.

REFERÊNCIAS

- ANDRADE, Winston Aparecido; MIRANDA, Leonardo de Jesus; ACHIDA, Thiago Akoto Cordelisse. Tipos de previsão de demanda e a aplicação em indústria automotiva paulista. REFAS: Revista FATEC Zona Sul, 2017.
- BALLOU, Ronald H. Gerenciamento da cadeia de suprimentos: logística empresarial. 5. ed. Porto Alegre: Bookman, 2006. 616 p.
- CASONATTO, Liziane. Integração de técnicas de previsão de demanda e controle de estoques: um estudo de caso em uma empresa do setor de joias folheadas. 2017. Monografia (Engenharia de Produção) – Universidade do Vale do Taquari, Lajeado, 2017.
- ELSAYED, E.; BOUCHER, T. Analysis and control of production systems. 2. ed. New Jersey: Prentice-Hall, 1994.
- FERNANDES, F. C. F.; GODINHO FILHO, M. Planejamento e controle da produção: dos fundamentos ao essencial. 1. ed. São Paulo: Atlas, 2010.
- GERHARDT, Tatiana Engel; SILVEIRA, Denise Tolfo. Métodos de pesquisa. 1. ed. Porto Alegre: Editora da UFRGS, 2009. 120 p.
- GIL, Antonio Carlos. Como elaborar projetos de pesquisa. 5. ed. São Paulo: Atlas, 2010. xvii, 184 p.
- HIGUCHI, Agnaldo Keiti. A previsão de demanda de produtos alimentícios perecíveis: três estudos de caso. REA – Revista Eletrônica de Administração, v. 5, n. 2, 2006.
- KOTLER, Philip. Administração de marketing. 5. ed. São Paulo: Atlas, 1998.
- LOPES, Héber Guilherme Tavares et al. Análise e previsão de demanda: estudo de caso em uma empresa produtora de alimentos. 2014.
- LUSTOSA, L. et al. Planejamento e controle da produção. 4. ed. Rio de Janeiro: Elsevier, 2008.
- MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven C.; HYNDMAN, Rob J. Forecasting: methods and applications. 3. ed. Hoboken: Wiley, 1998.
- MOREIRA, Daniel Augusto. Administração da produção e operações. 2. ed. São Paulo: Cengage Learning, 2008.
- NETO, Horácio Fernando Gonçalves Rabelo. Aplicação de métodos quantitativos de previsão de demanda em uma fábrica de ração em expansão. 2023.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. Revista Produção, São Paulo, 2001.
- SALGADO, Giovanna Costa et al. Modelo de previsão de demanda para a hamburgueria Osnir. 2022.
- SANTOS, Vanessa Moura. Aplicação do modelo de previsão de demanda de decomposição clássica de série temporal em um restaurante universitário. 2023.

SEBRAE. Tendências para o setor de beleza em 2024. Disponível em: <https://digital.sebraers.com.br/blog/estrategia/tendencias-para-o-setor-de-beleza-em-2024/>. Acesso em: 7 jun. 2025.

SILVA, Bráulio Wilker Silva de Almeida Lacerda. Gestão de estoques: planejamento, execução e controle. João Monlevade: BWS Consultoria, 2020.

SPADOTTO, Priscila Eburneo Laposta. Construção de ferramenta de previsão de demanda em um centro de material e esterilização. 2024.

STEVENSON, W. J. Administração das operações de produção. 6. ed. Rio de Janeiro: LTC, 2001. 701 p.

STEVENSON, Willian J. Operations management. 14. ed. New York: McGraw-Hill Education, 2018.

TUBINO, D. F. Planejamento e controle da produção: teoria e prática. São Paulo: Atlas, 2007.

VIEITOS, Eduardo dos Santos. Análise e aplicação de métodos de previsão de demanda para uma empresa de distribuição de produtos. 2023. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal Fluminense, Escola de Engenharia, Programa de Pós-Graduação Stricto Sensu em Engenharia de Produção, Niterói, 2023.