



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA QUÍMICA
CURSO DE GRADUAÇÃO EM ENGENHARIA QUÍMICA

JOÃO VICTOR MORAES AMORIM

**USO DE SÉRIES TEMPORAIS E SISTEMAS DE *FORECASTING* COMO
FERRAMENTAS DE PREDIÇÃO DE DEMANDA NA INDÚSTRIA 4.0**

Recife

2023

JOÃO VICTOR MORAES AMORIM

**USO DE SÉRIES TEMPORAIS E SISTEMAS DE *FORECASTING* COMO
FERRAMENTAS DE PREDIÇÃO DE DEMANDA NA INDÚSTRIA 4.0**

Trabalho de Conclusão de Curso
apresentado ao Curso de Graduação em
Engenharia Química da Universidade
Federal de Pernambuco, Centro de
Tecnologia e Geociências, como requisito
parcial para a obtenção do grau de
Bacharel em Engenharia Química.

Orientadora: Profa. Eliane Bezerra de
Moraes Medeiros

Recife
2023

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Amorim, João Victor Moraes.

Uso de séries temporais e sistemas de forecasting como ferramentas de
predição de demanda na Indústria 4.0 / João Victor Moraes Amorim. - Recife,
2023.

58 : il., tab.

Orientador(a): Eliane Bezerra de Moraes Medeiros

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Engenharia Química -
Bacharelado, 2023.

Inclui referências, apêndices.

1. Aroma. 2. Demanda. 3. Indústria. 4. PCP. 5. Previsão. I. Medeiros,
Eliane Bezerra de Moraes. (Orientação). II. Título.

660 CDD (22.ed.)

JOÃO VICTOR MORAES AMORIM

**USO DE SÉRIES TEMPORAIS E SISTEMAS DE *FORECASTING* COMO
FERRAMENTAS DE PREDIÇÃO DE DEMANDA NA INDÚSTRIA 4.0**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Química da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do grau de Bacharel em Engenharia Química.

Aprovado em: 05/05/2023.

BANCA EXAMINADORA

Documento assinado digitalmente

 ELIANE BEZERRA DE MORAES MEDEIROS
Data: 08/06/2023 17:04:28-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dra. Eliane Bezerra de Moraes Medeiros (Orientadora)
Universidade Federal de Pernambuco

Documento assinado digitalmente

 NELSON MEDEIROS DE LIMA FILHO
Data: 08/06/2023 17:28:33-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Nelson Medeiros de Lima Filho (1º Examinador)
Universidade Federal de Pernambuco

Documento assinado digitalmente

 RAFAEL ARAÚJO MELO
Data: 08/06/2023 18:26:53-0300
Verifique em <https://validar.iti.gov.br>

Dr. Rafael Araújo Melo (2º Examinador)
Universidade Federal de Pernambuco

DEDICATÓRIA

Dedico esse trabalho às minhas três mães, Isabel Cristina, Maria José e Maria da Conceição que sempre acreditaram em mim e moveram todos os obstáculos possíveis para que eu chegasse até aqui.

AGRADECIMENTOS

Agradeço primeiramente à minha mãe, Isabel Cristina Moraes da Silva, que me ofereceu todo o suporte para que eu estudasse em uma cidade diferente da nossa e esteve ao meu lado em cada pequena etapa dessa jornada.

À minha avó e tia, Maria José do Nascimento Amorim e Maria da Conceição do Nascimento Amorim, as quais me educaram desde o berço e ensinaram os valores sem os quais eu jamais teria conseguido chegar até aqui.

A todos os amigos que fiz durante o período de graduação, em especial a Fabian Cavalcanti de Miranda Filho e Thaísa Magalhães Elvas, os quais estiveram sempre ao meu lado em cada disciplina cursada e contribuíram imensamente para a minha formação.

À Elementus Júnior Consultoria, uma verdadeira família, o local que me acolheu dentro da universidade e me fez crescer exponencialmente enquanto pessoa e profissional.

À professora Eliane Bezerra de Moraes Medeiros, que prestou todo o auxílio necessário para a elaboração deste trabalho.

RESUMO

A indústria de aromas é um segmento em constante crescimento, sendo responsável pela produção de aromas utilizados em diversos produtos. Em um ambiente altamente competitivo, é importante que as empresas do ramo mantenham um bom controle do processo para garantir eficiência e eficácia na produção. O Planejamento e Controle da Produção (PCP) é, portanto, uma função essencial para o sucesso desse tipo de empresa. Este trabalho de conclusão de curso tem como objetivo aplicar técnicas de análise de séries temporais e métodos quantitativos de previsão de demanda nos produtos de uma indústria de aromas. A análise de séries temporais é uma abordagem estatística que se concentra na análise de padrões em dados históricos para prever o comportamento futuro. Para isso, foi importante identificar os diferentes tipos de demanda e características como tendência e sazonalidade, para escolher o método de previsão mais adequado. Para a previsão da demanda foram aplicados os métodos quantitativos de Média Móvel Simples, Suavização Exponencial Simples, de Holt e de Winters em dados históricos de vendas de quatro tipos de aromas para obter as previsões mais precisas possíveis da demanda futura. Dois produtos apresentaram pouca demanda tendencial, e nesses casos os métodos com maior acurácia foram os de Média Móvel e Suavização Exponencial Simples. O terceiro produto exibiu uma curva de tendência crescente bem acentuada e para ele o melhor método foi o de Suavização Exponencial Dupla de Holt. Por fim, o último produto apresentou pouca tendência com ciclos sazonais, e o método que melhor se ajustou a ele foi o de Winters. Dito isso, é possível utilizar as previsões obtidas como insumos para otimizar a produção e atender as demandas futuras, garantindo a qualidade da operação e a satisfação dos clientes da empresa.

Palavras-chave: Aroma; Demanda; Indústria; PCP; Previsão.

ABSTRACT

The flavor industry is a constantly growing segment, responsible for the production of flavors used in various products. In a highly competitive environment, it is important for companies in the industry to maintain good process control to ensure efficiency and effectiveness in production. Production Planning and Control (PPC) is therefore an essential function for the success of this type of company. The aim of this work is to apply time series analysis techniques and quantitative demand forecasting methods to products in a flavor industry. Time series analysis is a statistical approach that focuses on analyzing patterns in historical data to predict future behavior. To do this, it was important to identify different types of demand and characteristics such as trend and seasonality, to choose the most appropriate forecasting method. For demand forecasting, the quantitative methods of Simple Moving Average, Simple Exponential Smoothing, Holt and Winters were applied to historical sales data of four types of flavors to obtain the most accurate possible forecasts of future demand. Two products showed little trend demand, and in these cases the methods with the highest accuracy were Simple Moving Average and Simple Exponential Smoothing. The third product exhibited a well-defined increasing trend, and the best method for it was Holt's Double Exponential Smoothing. Finally, the last product showed little trend with seasonal cycles, and the method that best fit it was Winters. That being said, the forecasts obtained can be used as inputs to optimize production and meet future demands, ensuring the quality of the operation and customer satisfaction of the company.

Keywords: Demand; Flavor; Forecast; Industry; PPC

LISTA DE FIGURAS

Figura 1 – Séries temporais	19
Figura 2 – Características de uma série temporal	20
Figura 3 – Tipos de tendência numa série temporal	20
Figura 4 – Série temporal com ciclos	21
Figura 5 – Série temporal com sazonalidade	21
Figura 6 – Fluxograma das etapas de construção dos sistemas de <i>forecasting</i>	28
Figura 7 – Histórico de vendas do produto 05623	29
Figura 8 – Métodos quantitativos aplicados à série temporal do produto 05623	30
Figura 9 – Histórico de vendas do produto 06801	33
Figura 10 – Métodos quantitativos aplicados à série temporal do produto 06801	34
Figura 11 – Histórico de vendas do produto 00020	38
Figura 12 – Métodos quantitativos aplicados à série temporal do produto 00020	38
Figura 13 – Histórico de vendas do produto 06199	42
Figura 14 – Métodos quantitativos aplicados à série temporal do produto 06199	43

LISTA DE TABELAS

Tabela 1 – Previsão de demanda usando Média Móvel Simples na série temporal do produto 05623	31
Tabela 2 – Previsão de demanda a partir de Suavização Exponencial Simples na série temporal do produto 05623	32
Tabela 3 – Previsão de demanda usando Média Móvel Simples na série temporal do produto 06801	35
Tabela 4 – Previsão de demanda a partir de Suavização Exponencial Simples na série temporal do produto 06801	36
Tabela 5 – Previsão de demanda pelo método de Holt na série temporal do produto 06801	37
Tabela 6 – Previsão de demanda usando Média Móvel Simples na série temporal do produto 00020	39
Tabela 7 – Previsão de demanda a partir de Suavização Exponencial Simples na série temporal do produto 00020	40
Tabela 8 – Previsão de demanda pelo método de Holt na série temporal do produto 00020	41
Tabela 9 – Previsão de demanda pelo método de Winters na série temporal do produto 00020	43

LISTA DE ABREVIATURAS E SIGLAS

ABIAM	Associação Brasileira da Indústria e Comércio de Ingredientes e Aditivos para Alimentos
EAr	Erro aritmético
EArA	Erro aritmético acumulado
EMA	Erro médio absoluto
IFF	<i>International Flavours and Fragances</i>
MMS	Média Móvel Simples
PCP	Planejamento e Controle da Produção
kg	Quilograma
TS	<i>Tracking Signal</i>

LISTA DE ABREVIATURAS

kg Quilograma

LISTA DE SIGLAS

ABIAM	Associação Brasileira da Indústria e Comércio de Ingredientes e Aditivos para Alimentos
EAr	Erro aritmético
EArA	Erro aritmético acumulado
EMA	Erro médio absoluto
IFF	<i>International Flavours and Fragances</i>
MMS	Média Móvel Simples
PCP	Planejamento e Controle da Produção
TS	<i>Tracking Signal</i>

LISTA DE SÍMBOLOS

α	Alfa
β	Beta
{ }	Conjunto
\$	Cifrão
=	Igual
+	Mais
\pm	Mais ou menos
-	Menos
	Módulo
()	Parênteses
%	Porcentagem
Σ	Somatório

SUMÁRIO

1.	INTRODUÇÃO	16
2.	FUNDAMENTAÇÃO TEÓRICA	19
2.1	SÉRIES TEMPORAIS	19
2.2	PREVISÃO DE DEMANDA	21
2.2.1	Modelos univariados de previsão de demanda	22
2.2.1.1	Modelo de Média Móvel Simples	22
2.2.1.2	Modelo de Suavização Exponencial Simples	23
2.2.1.3	Modelo de Suavização Exponencial Dupla de Holt	24
2.2.1.4	Modelo Sazonal Multiplicativo de Winters	25
2.2.2	Monitoramento de previsão	26
2.2.2.1	Erros de previsão	27
2.2.2.2	<i>Tracking Signal</i>	27
3.	METODOLOGIA	28
4.	RESULTADOS E DISCUSSÃO	30
5.	CONCLUSÃO	45
	REFERÊNCIAS	47
	APÊNDICES	50

1. INTRODUÇÃO

Segundo Yamasaki (2020), os aromas são aditivos com propriedades de melhorar as características sensoriais de alimentos e bebidas. As indústrias de alimentos fazem o uso dos aromas, pois estes são responsáveis pela caracterização do sabor do produto final, deixando-o mais atrativo para o consumidor. Eles são moléculas orgânicas e de massa molecular inferior a 400 Dalton, relativamente voláteis e muito sensíveis ao ar, aquecimento, luz e umidade, sendo esses fatores causadores de efeitos indesejáveis e perdas significativas nos compostos aromatizantes.

O ramo de aromas é dominado por empresas multinacionais, com algumas exceções. As empresas produtoras de aromas fornecem não apenas para empresas do setor de alimentos, mas também para as indústrias de perfumaria, higiene e limpeza (GOUVEIA, 2006).

O mercado brasileiro de ingredientes e aditivos fatura anualmente entre R\$1,5 bilhão e R\$2 bilhões, segundo Helvio Tadeu Collino, presidente da Associação Brasileira da Indústria e Comércio de Ingredientes e Aditivos para Alimentos (ABIAM). Os aromas respondem por cerca de 50% desse faturamento e o restante agrega todos os outros ingredientes e aditivos.

Gouveia (2006) afirma que grandes multinacionais, como as suíças *Givaudan* e *Firmenich*, a americana *IFF* (International Flavours and Fragrances), a alemã *Synrise* e a inglesa *Quest* são as empresas que dominam o mercado mundial, mas que algumas nacionais também têm sua fatia no mercado brasileiro. A Duas Rodas, por exemplo, é uma empresa brasileira centenária que, além de aromas, desenvolve outros ingredientes e aditivos. Há também a *VittaFlavor*, também de capital 100% nacional, fundada há treze anos, que figura entre as seis maiores fabricantes de aromas instaladas no Brasil e possui um departamento de pesquisa de produtos naturais que estuda os componentes voláteis responsáveis pelos sabores das frutas tropicais brasileiras.

Como um segmento em crescimento, destaca-se como objetivo para a indústria de aromas alcançar maiores produções utilizando o mesmo ou até um menor grau de utilização dos seus recursos. Para alcançar este fim são necessárias adequações em processos de produção, qualidade, manutenção, logística, dentre outros (PONTES, 2018).

A função de Planejamento e Controle da Produção (PCP) surge com o objetivo de planejar e controlar a produção de forma que a empresa atinja esses requisitos do modo mais eficiente possível. É a área responsável por gerenciar as atividades de produção visando satisfazer continuamente a demanda dos consumidores, e reduzir os custos relacionados aos processos, como matéria-prima, insumos, mão-de-obra e maquinários. A falta desse planejamento impacta diretamente no processo produtivo e logístico, ocasionando retrabalho, transtornos com atrasos em entregas, falta de estoque de materiais produtivos, comprometendo a credibilidade com clientes e fornecedores e gerando sobrecarga sobre os colaboradores (ESTENDER, 2017).

Slack (2009) reitera que programar e controlar a produção consiste essencialmente em conciliar o fornecimento de produtos e serviços com a demanda de pedidos. Um grande desafio é atender a demanda de vendas, uma vez que é necessário elaborar um ou mais planos para a produção de um produto.

Corrêa (1999) fala que a depender da estrutura da empresa, muitas vezes não se pode ter altos níveis de estoque de matéria-prima e produto acabado. É necessário calcular os giros e definir pontos ótimos para o estoque uma vez que este oferece risco de prejuízo para o caixa da empresa.

1.1 OBJETIVOS

Este trabalho visa a aplicação de conceitos de Planejamento e Controle da Produção que tange ao atendimento e previsão de demanda de pedidos.

1.1.1 Objetivos gerais

O projeto tem como objetivo geral analisar o histórico e tipos de demanda de um grupo de produtos de uma indústria de aromas e elaborar suas respectivas previsões de venda a partir de métodos quantitativos.

1.1.2 Objetivos específicos

Os objetivos específicos são:

- Analisar as séries temporais referentes ao histórico de venda de quatro tipos de aroma;
- Classificar e analisar os tipos de demanda para estes produtos;

- Desenvolver modelagens de previsão utilizando os métodos quantitativos estudados;
- Comparar e definir os métodos quantitativos que melhor preveem as demandas futuras.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 SÉRIES TEMPORAIS

Segundo Morettin (1987), uma série temporal é um conjunto de observações ordenadas no tempo, não necessariamente igualmente espaçadas, que apresentam dependência serial, isto é, dependência entre instantes de tempo. Uma grande quantidade de fenômenos de natureza física, biológica, econômica podem ser enquadrados nessa categoria. Alguns exemplos de séries temporais podem ser observados na Figura 1 a seguir.

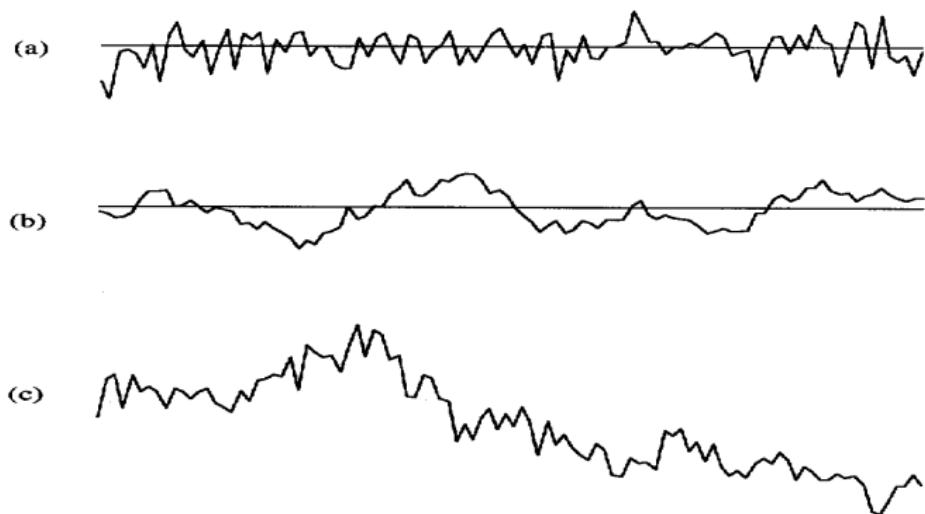


Figura 1 – Séries temporais.

Fonte: Box & Luceño (1997).

De acordo com Gutierrez (2003), no geral, ao se estudar uma série temporal se está interessado em:

- Análise e modelagem da série temporal: visando descrever a série, verificar suas características mais relevantes e suas possíveis relações com outras séries;
- Previsão na série temporal: com o objetivo de, a partir de valores históricos, estimar previsões de curto prazo. O número de instantes à frente para o qual é feita a previsão é chamado de horizonte de previsão.

A maneira tradicional de analisar uma série temporal é através da sua decomposição nas componentes de tendência, ciclo e sazonalidade, as quais estão ilustradas na Figura 2.

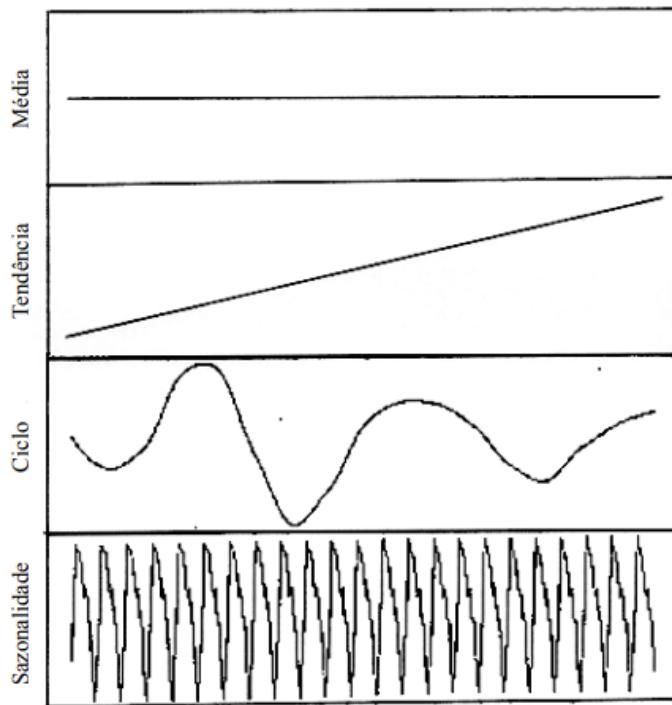


Figura 2 – Características de uma série temporal.

Fonte: Adaptado de Makridakis *et al.* (1998)

A tendência de uma série indica o seu comportamento no longo prazo, ou seja, se ela cresce, decresce ou permanece estável, e qual a velocidade destas mudanças (GUTIERREZ, 2003). Os tipos mais comuns de tendência são constante, linear e quadrática, as quais estão exemplificadas na Figura 3.

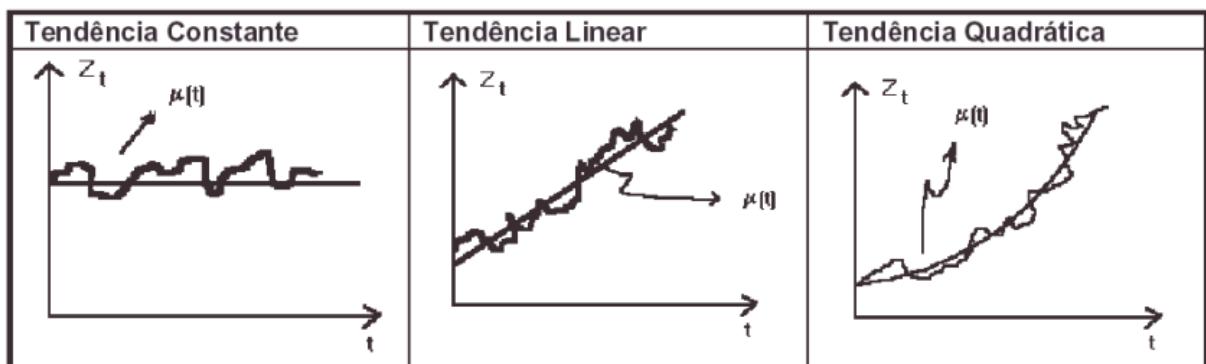


Figura 3 – Tipos de tendência numa série temporal.

Fonte: Adaptado de Makridakis *et al.* (1998)

Segundo Gutierrez (2003), os ciclos são caracterizados pelas oscilações de subida e de queda nas séries, de forma suave e repetida, ao longo da componente de tendência, como observado na Figura 4. Alguns ciclos podem ser vistos em séries que retratam atividades econômicas ou ciclos meteorológicos.

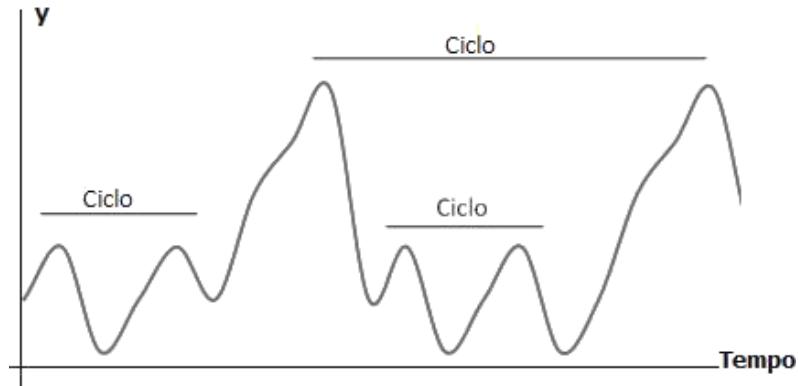


Figura 4 – Série temporal com ciclos.

Fonte: Pinto (2009)

A sazonalidade em uma série corresponde às oscilações de subida e de queda que sempre ocorrem em um determinado período do ano, do mês, da semana ou do dia. A diferença essencial entre as componentes sazonal e cíclica é que a primeira possui movimentos facilmente previsíveis, ocorrendo em intervalos regulares de tempo, enquanto que movimentos cíclicos tendem a ser irregulares. (GUTIERREZ, 2003). A Figura 5 exemplifica a sazonalidade na demanda de passagens de avião entre os anos de 1950 e 1960.

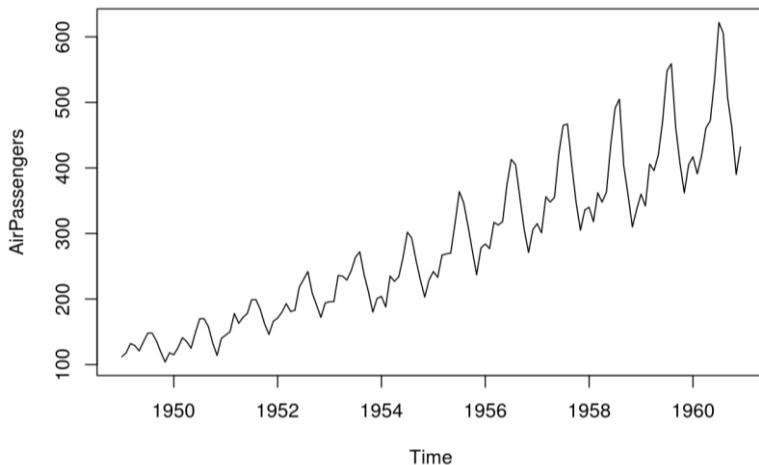


Figura 5 – Série temporal com sazonalidade.

Fonte: Gonzaga (2017)

2.2 PREVISÃO DE DEMANDA

Previsões de demanda desempenham um importante papel na operacionalização de diversos aspectos do gerenciamento da produção, como na gestão de estoques e no desenvolvimento de planos agregados de produção. Elas

são elaboradas utilizando métodos quantitativos, qualitativos ou combinações de ambos (MENTZER, 1984).

Os métodos quantitativos, também denominados métodos de *forecasting*, baseiam-se em dados que descrevem a variação da demanda ao longo do tempo, sob a forma de séries temporais. Métodos qualitativos baseiam-se em opiniões de especialistas, sendo vulneráveis a tendências que podem comprometer a confiabilidade de seus resultados e têm sido, historicamente, os mais utilizados na previsão da demanda (MENTZER, 1984).

Mentzer (1984) ainda fala que os procedimentos de previsão utilizados na prática variam muito, podendo ser simples e intuitivos, com pouca análise dos dados, ou complexos e racionais, envolvendo um considerável trabalho de interpretação de séries temporais.

De acordo com Gutierrez (2003), dentre os procedimentos estatísticos de previsão podem ser citados:

- Modelos Univariados: inclui os modelos que se baseiam em uma única série histórica. Podem ser citados a decomposição por componentes não observáveis, os modelos automáticos que incorporam modelos de regressão, as médias móveis, suavizações exponenciais, ajustes sazonais, dentre outros;
- Modelos de Função de Transferência: são aqueles nos quais a série de interesse é explicada não só pelo seu passado histórico, como também por outras séries temporais não correlacionadas entre si;
- Modelos Multivariados: modelam simultaneamente duas ou mais séries temporais sem qualquer exigência em relação à direção da causalidade entre elas.

2.2.1 Modelos univariados de previsão de demanda

2.2.1.1 Modelo de Média Móvel Simples

O modelo de média móvel simples (MMS) é empregado para estimar a média de uma série temporal, ou parte da série temporal de uma demanda. Segundo Medeiro (2021), esse método possui grande utilidade, podendo ser utilizado em previsões quando a demanda não possui influências sazonais e tendências acentuadas, ou seja, possui razoável estabilidade.

Partindo de um simples exemplo: média de preços de um produto a cada 3 meses. Conforme os meses vão passando, novos dados vão substituindo os valores mais antigos, formando uma base amostral para elaboração da média que varia ao longo do tempo. A variação nessa média recebe o nome de janela móvel, e no exemplo citado, são de 3 meses. O comportamento desses preços pode ser analisado a partir da janela móvel pertencente à série temporal da previsão, a qual é gerada pela Equação 1.

$$\hat{z}_t = \frac{\text{preço}_1 + \text{preço}_2 + \text{preço}_3}{3} \quad (1)$$

Nessa lógica de raciocínio, a MMS de um conjunto aleatório T , composto por S valores, $T = \{S_1, S_2, \dots, S_n\}$ pode ser generalizada pela Equação 2.

$$\hat{z}_t = \frac{\sum_0^n S_n}{n} \quad (2)$$

Onde:

- \hat{z}_t é a previsão da demanda para o tempo t ;
- $\sum_0^n S_n$ é a janela móvel utilizada para o cálculo da média;
- n é a quantidade de períodos utilizada no cálculo da média

2.2.1.2 Modelo de Suavização Exponencial Simples

Os modelos de Suavização Exponencial são amplamente utilizados para previsão de demanda devido a sua simplicidade, facilidade de ajustes e boa acurácia. Estes métodos usam uma ponderação distinta para cada valor observado na série temporal, de modo que valores mais recentes da demanda real ou da previsão possam receber pesos maiores ou não. Assim, os pesos formam um conjunto que decai exponencialmente a partir de valores mais recentes (MAKRIDAKIS et al., 1998).

Makridakis et al. (1998) ainda fala que se a série temporal se mantém constante sobre um nível médio, a suavização exponencial simples pode ser usada para a previsão de valores futuros. Sua representação matemática é dada pela Equação 3.

$$\hat{z}_{t+1} = \alpha z_t + (1 - \alpha) \hat{z}_t \quad (3)$$

Onde:

- \hat{z}_{t+1} é a previsão da demanda para o tempo $t+1$, feita no período atual t ;
- z_t é o valor observado na série temporal para o tempo t ;

- α é a constante de suavização, assumindo valores arbitrários entre 0 e 1;

2.1.2.3 Modelo de Suavização Exponencial Dupla de Holt

De acordo com Makridakis *et al.* (1998), o modelo de Holt pode ser utilizado, de maneira satisfatória, em séries temporais com tendências lineares bem definidas. Este modelo emprega duas constantes de suavização, α e β , que podem oscilar entre 0 e 1, e é representado por três Equações 4, 5 e 6.

$$L_t = \alpha z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (4)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (5)$$

$$\hat{z}_{t+k} = L_t + kT_t \quad (6)$$

Onde:

- α e β são constantes de suavização, assumindo valores arbitrários entre 0 e 1;
- L_t é a estimativa do nível em que a série temporal se encontra;
- z_t é o valor observado na série temporal para o tempo t ;
- T_t é estimativa da inclinação da série temporal;
- \hat{z}_{t+k} é a previsão da demanda para os próximos k períodos;

Assim como na suavização exponencial simples, o método de Holt requer valores iniciais, neste caso L_{t-1} e T_{t-1} . Uma alternativa para estes cálculos iniciais é igualar L_{t-1} ao último valor observado na série temporal e calcular uma média da declividade nas últimas observações para T_{t-1} . Uma outra forma de cálculo é a regressão linear simples aplicada aos dados da série temporal, onde se obtém o valor da declividade da série temporal e de L_{t-1} em sua origem.

2.1.2.4 Modelo Sazonal Multiplicativo de Winters

De acordo com Pellegrini (2001) *apud* Makridakis (1998), o modelo multiplicativo de Winters é utilizado na modelagem de dados sazonais onde a amplitude do ciclo sazonal varia com o passar do tempo. Sua representação matemática vem dada pelas Equações 7, 8, 9 e 10.

$$L_t = \alpha \frac{z_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (7)$$

$$T_t = \beta(L_{t-1} + T_{t-1}) + (1 - \beta)T_{t-1} \quad (8)$$

$$S_t = \gamma \frac{z_t}{L_t} + (1 - \gamma)S_{t-s} \quad (9)$$

$$\hat{z}_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (10)$$

Onde:

- S é uma estação completa da sazonalidade (por exemplo: s é igual a 12 quando se tem dados mensais e sazonalidade anual);
- L_t representa o nível em que a série temporal se encontra;
- T_t representa a tendência ou inclinação da série temporal;
- S_t representa a sazonalidade da série temporal;
- \hat{z}_{t+k} é a previsão para k períodos à frente;
- z_t é o valor observado na série temporal para o tempo t ;
- γ é a constante de suavização que controla o peso relativo a sazonalidade, variando entre 0 e 1

A Equação 7 difere da equação que trata do nível da série no modelo de Holt, já que o primeiro termo é dividido por um componente sazonal, eliminando assim a flutuação sazonal de z_t . A Equação 8 é exatamente igual à equação da tendência no método de Holt. Já a Equação 9 faz um ajuste sazonal nas observações z_t .

Segundo Makridakis *et al.* (1998), como todos os métodos de suavização exponencial, os modelos de Winters necessitam valores iniciais dos componentes de nível, tendência e sazonalidade para dar início aos cálculos. Para a estimativa do componente sazonal, necessita-se no mínimo uma estação completa de observações, ou seja, S períodos. As estimativas iniciais do nível e da tendência são feitas, então, no período S definido para o componente sazonal.

O estimador inicial para o nível da série é dado pela média da primeira estação, demonstrada pela Equação 11.

$$L_s = \frac{1}{s}(z_1 + z_2 + \dots + z_s) \quad (11)$$

O cálculo da estimativa inicial para a tendência requer duas estações completas ($2S$) é indicado pela Equação 12.

$$T_s = \frac{1}{s} \left(\frac{z_{s+1} - z_1}{s} + \frac{z_{s+2} - z_2}{s} + \dots + \frac{z_{s+s} - z_s}{s} \right) \quad (12)$$

Para o componente sazonal, utilizam-se S estimativas iniciais $S_1 = \frac{z_1}{L_s}, S_2 = \frac{z_2}{L_s}, \dots, S_s = \frac{z_s}{L_s}$.

2.2.2 Monitoramento de previsão

De acordo com Tamaki (2016) *apud* Gardner (1985), o objetivo do monitoramento de previsão é detectar os erros tendenciosos o mais rápido possível. Eles também afirmam que na maioria dos sistemas de monitoramento, os erros de previsão devem ser detectados automaticamente para garantir que o sistema permaneça sob controle. Também é dito que mudanças nas médias, ou as tendências e sazonalidades devem ser detectadas rapidamente para garantir que o modelo de previsão se adapte aos novos dados ou que ele seja alterado para um novo modelo.

Tamaki (2016) *apud* Trigg (1964) falam que é importante incorporar alguma forma de monitoramento automático de controle de previsão para garantir que o sistema permaneça sob controle. Segundo eles, se um modelo de suavização exponencial simples for aplicado em uma série temporal com tendência, a previsão terá consistentemente um atraso. Um segundo caso é na existência de variações sazonais não identificadas, as quais podem causar erros tendenciosos. Monitorar ajuda a detectar estas situações para que melhores métodos de previsão sejam introduzidos.

2.2.2.1 Erros de previsão

Os erros são formas de medir a acurácia das previsões. Eles auxiliam na interpretação da qualidade dos valores previstos, pois indicam se eles estão sistematicamente acima ou abaixo da demanda real, a magnitude dessas variações e a presença de *outliers*.

- Erro aritmético: é a diferença entre o valor previsto e a demanda real na série temporal, ou seja, $e_t = \hat{z}_t - z_t$;
- Erro absoluto: é o módulo da diferença entre o valor previsto e a demanda real, sendo representado por $|e_t| = |\hat{z}_t - z_t|$;
- Erro médio absoluto: é a média da soma dos erros absolutos, $EMA = \frac{\sum |e_t|}{n}$, que indica a dispersão do erro acumulado a cada previsão da série;

2.2.2.2 Tracking Signal

De acordo com McClain (1988), o *Tracking Signal* (TS) promove um controle de qualidade para a previsão. Eles são medidores de erros de previsão acumulados que servem para sinalizar quando um modelo de previsão não está adequado. Ele é calculado pela razão entre a soma cumulativa dos erros aritméticos de previsão e o erro médio absoluto. A seguir encontra-se a expressão que calcula esse fator:

$$\text{Tracking Signal} = \frac{|\hat{z}_t - z_t|}{EMA} \quad (13)$$

onde $\hat{z}(t)$ é a previsão estimada e $D(t)$ é a demanda real no período. EMA é o desvio médio absoluto. Sua fórmula é a seguinte:

$$EMA = \frac{\sum |\hat{z}_t - z_t|}{n} \quad (14)$$

onde n é o número de períodos. Tendo isso, a fórmula para o *Tracking Signal* é:

$$\text{Tracking Signal} = \frac{|\hat{z}_t - z_t|}{\frac{\sum |\hat{z}_t - z_t|}{n}} \quad (15)$$

Os limites de controle para TS são independentes do período de tempo. Segundo Corrêa *et al.* (1997) os valores devem se distribuir em torno de zero, não ultrapassando o intervalo de ± 3 e ± 4 . Neste trabalho foi selecionado o limite de ± 4 .

3. METODOLOGIA

O presente trabalho possui duas frentes: a análise preliminar de séries temporais, onde serão classificados os tipos de demanda para diferentes produtos, e o desenvolvimento de modelos de *forecasting* para cada um deles, juntamente com a escolha do método mais adequado. As etapas envolvidas na elaboração deste estão dispostas sob a forma de fluxograma na Figura 6 a seguir.

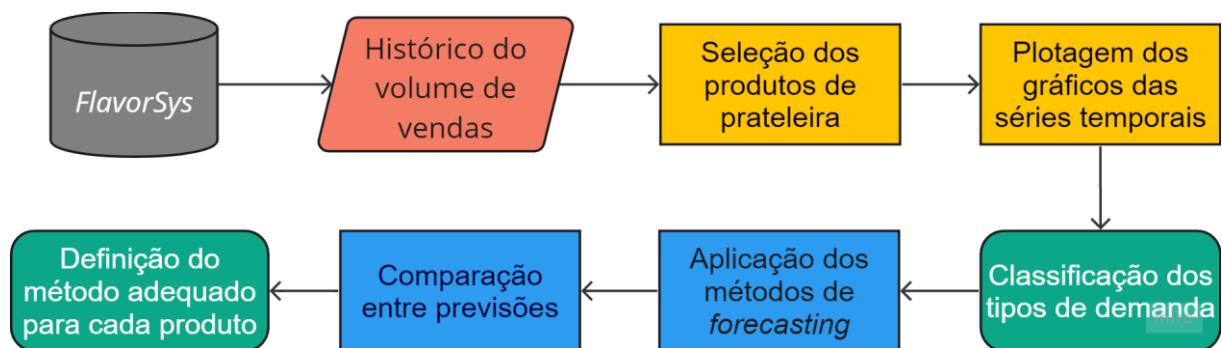


Figura 6 – Fluxograma das etapas de construção dos sistemas de forecasting.

Fonte: O Autor (2023)

O material base do trabalho foi o histórico de vendas de uma indústria de aromas. O relatório contendo os volumes vendidos dos produtos a cada mês, em quilogramas, entre os períodos de junho de 2020 e dezembro de 2022 foi gerado a partir do *FlavorSys*, o sistema integrado de gestão empresarial em uso na empresa até então.

Para obter maior impacto na cadeia produtiva foram selecionados quatro produtos que possuem vendas para, no mínimo, cinco clientes do portfólio da empresa. Eles fazem parte da linha de itens de prateleira e foram escolhidos pelo fato de representarem grandes parcelas do volume de vendas geral. São eles:

- 05623 – Coco Aroma Artificial;
- 06801 – Solução Amarelo Tartrazina;
- 00020 – Queijo Aroma Ident Nat;
- 06199 - Queijo Cond Prep

As séries temporais para cada um dos produtos foram estudadas individualmente, com seus gráficos plotados no Microsoft Excel 2016. A partir disso foram realizadas análises focadas em identificar quais tipos de demanda estavam presentes em cada caso.

O passo seguinte foi a aplicação dos métodos de *forecasting* em cada uma das séries temporais. As modelagens foram realizadas através do Excel e as análises atribuídas a elas foram puramente estatísticas numéricas, visando resguardar a imagem da empresa. Devido a isso, dados subjetivos oriundos de julgamento e perícia de especialistas não foram considerados para completar as discussões. A análise gráfica permite, em muitos casos, a identificação rápida de quais métodos se adequam à série temporal, portanto, as discussões desenvolvidas excluíram os métodos cujas curvas não apresentam comportamento semelhante à demanda real.

Os dados dos volumes de produção estão agrupados em 31 meses, portanto o período a que correspondem os dados das séries temporais é o mês. O horizonte abarcado para cada uma das previsões foi o período entre julho e dezembro de 2022 (seis meses) e as discussões foram realizadas com base neles. A partir dos resultados das modelagens foram aplicados os monitoramentos de previsão, os quais forneceram subsídios para a escolha dos métodos que geraram as melhores previsões de demanda.

4. RESULTADOS E DISCUSSÃO

O estudo de previsão da demanda concentra-se em quatro produtos do portfólio de uma empresa de aromas cujo nome não pode ser divulgado.

4.1 05623 - COCO AROMA ARTIFICIAL

A série de dados da demanda correspondente ao produto de código 05623, de nome comercial Coco Aroma Artificial, está presente sob a forma de tabela com um maior detalhamento de dados no Apêndice A e na Figura 7 a seguir.

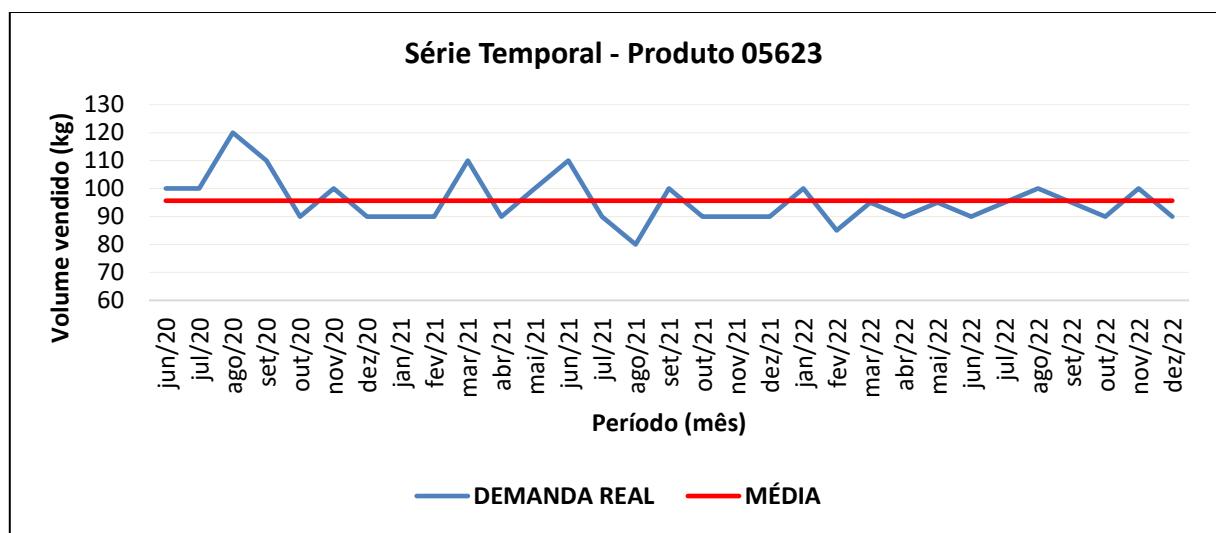


Figura 7 – Histórico de vendas do produto 05623.

Fonte: O Autor (2023)

Observa-se no gráfico que o histórico de demanda não apresenta nenhum comportamento de tendência e que seus valores oscilam em torno da média geral, se classificando, portanto, como uma tendência constante.

Uma vez plotado o gráfico do histórico de vendas, foi estudado o método quantitativo que poderia prever com acurácia a demanda futura deste produto. Foram aplicados os modelos de média móvel, suavização exponencial simples, suavização exponencial dupla de Holt e o modelo sazonal multiplicativo de Winters, os quais podem ser vistos a seguir na Figura 8.

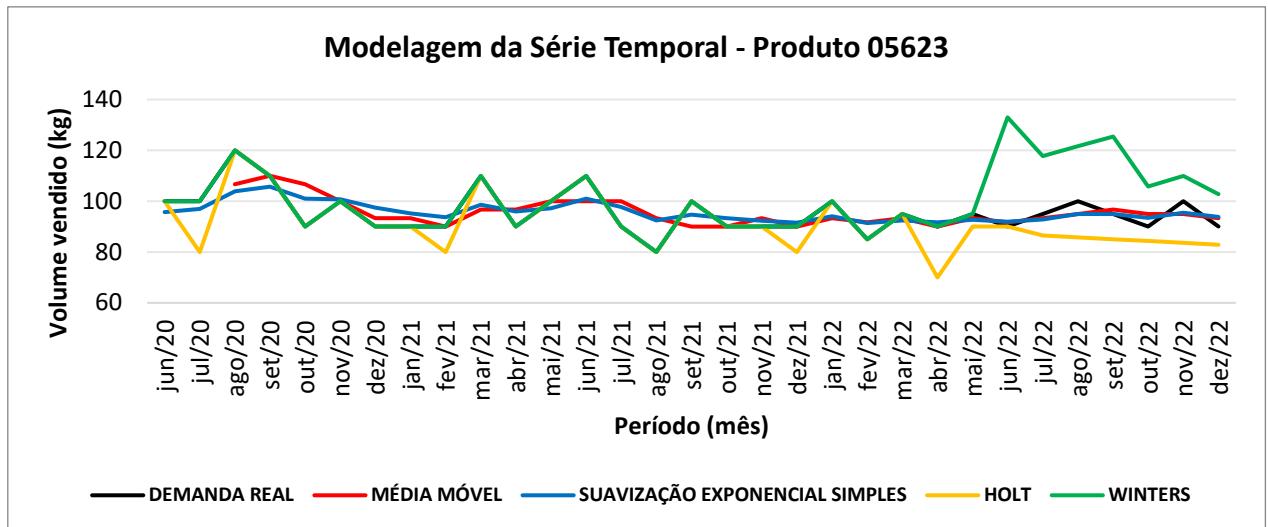


Figura 8 – Métodos quantitativos aplicados à série temporal do produto 05623.

Fonte: O Autor (2023)

Nela, a linha preta representa a evolução temporal dos dados de demanda real e as demais linhas as modelagens utilizando os métodos já citados. Graficamente fica claro que no horizonte de previsão estabelecido (julho a dezembro de 2022) os métodos com resultados que mais se aproximam dos valores subsequentes da série temporal são o de média móvel e o de suavização exponencial simples, o que é coerente, já que de acordo com Makridakis *et al.* (1998) esses modelos são aplicados e obtém maior precisão justamente em séries que se mantém constantes sob um nível médio. Dito isso, as discussões seguintes serão focadas nestes dois modelos.

No método de média móvel, as previsões foram calculadas a partir de janelas de três observações precedentes da série. A Tabela 1 a seguir contém o horizonte de seis previsões e seus respectivos monitoramentos através do *Tracking Signal*.

Tabela 1 – Previsão de demanda usando Média Móvel Simples na série temporal do produto 05623.

Período	Demanda real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	95	93,3	-1,7	6,7	5,6	1,2
ago/22	100	95,0	-5,0	1,7	5,8	0,3

set/22	95	96,7	1,7	3,3	5,9	0,6
out/22	90	95,0	5,0	8,3	6,1	1,4
nov/22	100	95,0	-5,0	3,3	6,4	0,5
dez/22	90	93,3	3,3	6,7	6,5	1,0

Fonte: O Autor (2023)

É possível observar que o erro aritmético entre demanda real e valor previsto em cada período é relativamente pequeno, oscilando entre ± 5 kg. Levando em conta que o método de previsão é apenas quantitativo e não houve perícia de especialistas, considera-se que os resultados obtidos apresentaram boa acurácia. Como prova, o cálculo do monitoramento está, o limite de ± 4 considerado por McClain (1998), indicando que os erros podem ser desprezados e os valores previstos estão dentro do padrão de qualidade aceitável.

Para o método de suavização exponencial simples foi adotada uma constante de suavização α igual a 0,3, a qual atribui peso maior ao valor previsto anteriormente ($1 - \alpha = 0,7$), do que ao histórico real de demanda para cálculo das previsões seguintes. A Tabela 2 a seguir contém o conjunto dos últimos seis valores previstos pelo modelo e os respectivos monitoramentos pelo *Tracking Signal*.

Tabela 2 – Previsão de demanda a partir de Suavização Exponencial Simples na série temporal do produto 05623.

Período	Demand real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	95	92,8	-2,2	2,2	8,3	0,3
ago/22	100	95,0	-5,0	-2,8	8,1	-0,3
set/22	95	95,0	0,0	-2,8	7,7	-0,4
out/22	90	93,5	3,5	0,7	7,5	0,1

nov/22	100	95,4	-4,6	-3,9	7,3	-0,5
dez/22	90	93,8	3,8	-0,1	7,2	0,0

Fonte: O Autor (2023)

Da mesma forma que no método anterior, o erro aritmético entre a demanda real e o valor previsto foi pequeno, oscilando entre -5kg e 3,8kg e apresentando uma boa acurácia. O *Tracking Signal* se manteve dentro dos limites aceitáveis, indicando que neste caso a previsão também é adequada.

A amplitude do erro aritmético no modelo de média móvel, de 10kg, foi maior que a do modelo de suavização exponencial simples, de 8,8kg, o que indica que o primeiro método possui mais desvios em relação à previsão que o segundo. Analisando também os desvios no *Tracking Signal* se tem que, dentro da faixa de ± 4 , o método que possui mais variação em relação à mediana (zero), também é o de média móvel, com um valor absoluto máximo de 1,4, contra 0,5 do método de suavização simples.

Após comparar os resultados obtidos em ambas as previsões é possível afirmar que o método de suavização exponencial simples é o mais fidedigno aos valores da demanda real do produto 05623.

4.2 06801 - SOLUÇÃO AMARELO TARTRAZINA

A série de dados completa da demanda correspondente ao produto de código 06801, de nome comercial Solução Amarelo Tartrazina, está apresentada sob a forma de tabela no Apêndice B e na Figura 9 a seguir.

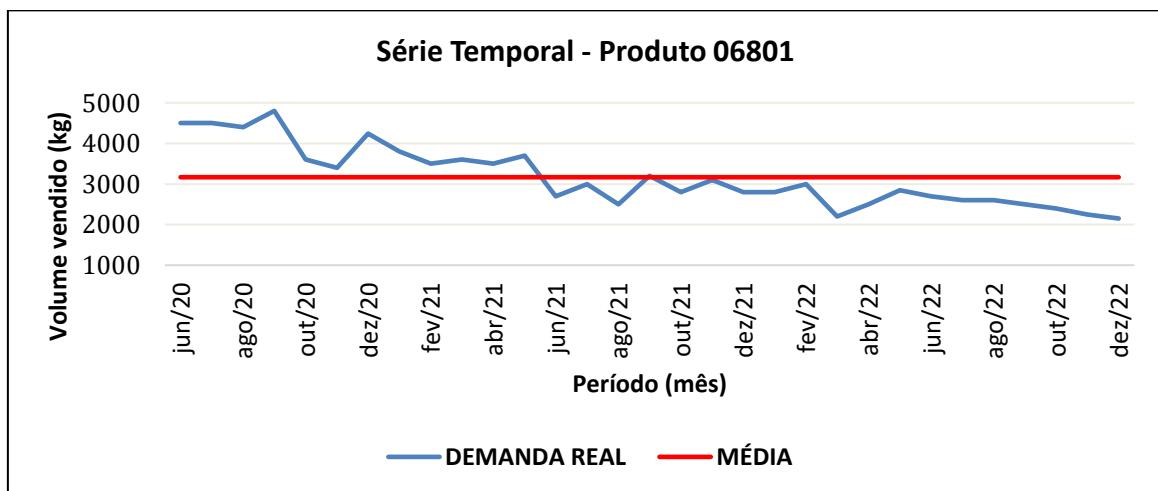


Figura 9 – Histórico de vendas do produto 06801.

Fonte: O Autor (2023)

Nota-se que o histórico de demanda desse produto apresenta uma discreta tendência decrescente com o passar do tempo, ficando acima da média apenas entre o período de junho de 2020 e maio de 2021, e em setembro de 2021.

Mais uma vez os modelos de média móvel, suavização exponencial simples, suavização exponencial dupla de Holt e sazonal multiplicativo de Winters foram aplicados na série temporal. As curvas correspondentes a cada um deles podem ser vistas na Figura 10 a seguir.

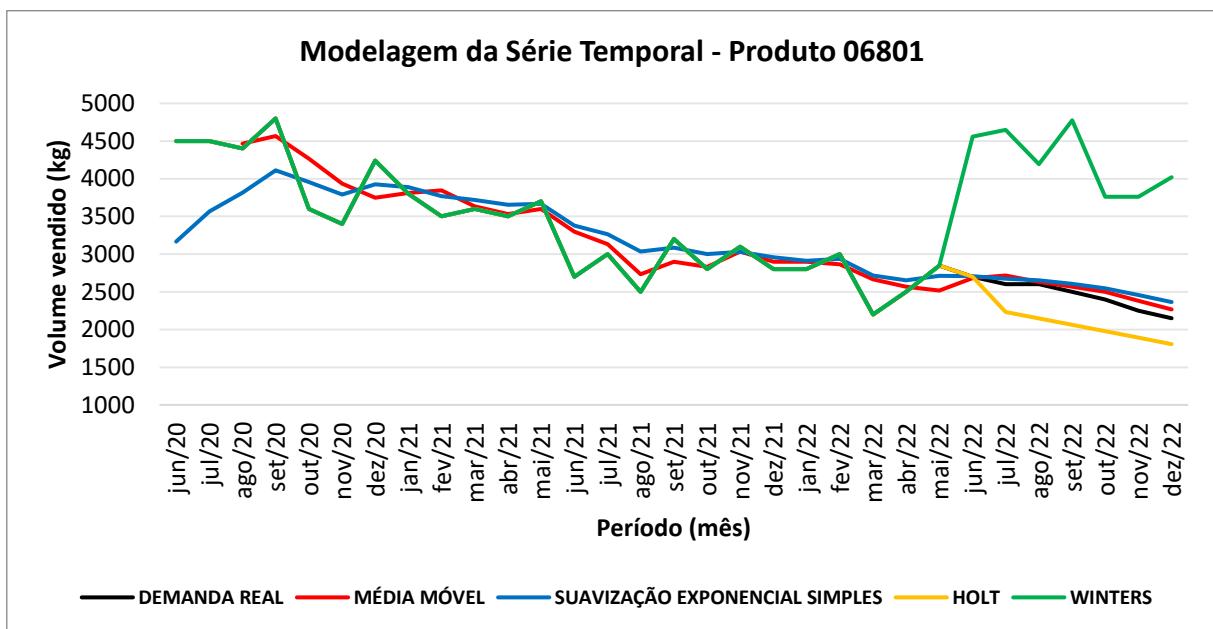


Figura 10 – Métodos quantitativos aplicados à série temporal do produto 06801.

Fonte: O Autor (2023)

Graficamente, os modelos que apresentam as curvas com comportamentos mais semelhantes aos da série temporal no horizonte de previsão estabelecido são o de média móvel e o de suavização exponencial simples. Tal observação é coerente pois esses métodos se aplicam melhor em séries temporais constantes, e como observado, a tendência presente na demanda desse produto é pouco acentuada.

Apesar da análise gráfica influenciar a escolha dos dois métodos citados como os mais próximos da série temporal, o método de Holt também descreve um comportamento parecido. Ele é utilizado em previsões de séries com tendências e por isso pode apresentar uma modelagem coerente para este produto. Portanto, serão analisados três métodos quantitativos.

A Tabela 3 a seguir contém o conjunto das previsões utilizando Média Móvel

para o produto 06801 e seu monitoramento por meio do *Tracking Signal*.

Tabela 3 – Previsão de demanda usando Média Móvel Simples na série temporal do produto 06801.

Período	Demanda real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	2600	2716,7	116,7	1866,7	237,3	7,9
ago/22	2600	2633,3	33,3	1900,0	238,8	8,0
set/22	2500	2566,7	66,7	1966,7	241,8	8,1
out/22	2400	2500,0	100,0	2066,7	246,4	8,4
nov/22	2250	2383,3	133,3	2200,0	252,4	8,7
dez/22	2150	2266,7	116,7	2316,7	257,7	9,0

Fonte: O Autor (2023)

Na aplicação deste método os erros aritméticos oscilam de forma aleatória entre 33,3 e 133,3kg, um comportamento esperado, já que no caso da média móvel as previsões são calculadas com base nos três valores imediatamente precedentes da demanda real, e por isso, são bastante sensíveis a *outliers* e tendências. Ao analisar os dados calculados de erro aritmético acumulado se observa uma tendência crescente, o que indica que a modelagem está se distanciando da série temporal a cada período subsequente.

O distanciamento citado é corroborado pelo *Tracking Signal*, que esteve fora do limite de ± 4 em todo o horizonte de previsão e apresenta valores crescentes que tendem a se distanciar ainda mais do intervalo de confiança. Dito isso, fica claro que o modelo de média móvel não é o método de previsão adequado para a demanda deste produto.

Na suavização exponencial simples foi adotada novamente uma constante de suavização α igual a 0,3. Os últimos seis valores previstos pelo modelo e os

respectivos monitoramentos pelo *Tracking Signal* estão dispostos na Tabela 4 a seguir.

Tabela 4 – Previsão de demanda a partir de Suavização Exponencial Simples na série temporal do produto 06801.

Período	Demanda real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	2600	2675,6	75,6	-184,9	321,3	-0,6
ago/22	2600	2652,9	52,9	-132,0	311,3	-0,4
set/22	2500	2607,0	107,0	-25,0	304,0	-0,1
out/22	2400	2544,9	144,9	119,9	298,6	0,4
nov/22	2250	2456,4	206,4	326,4	295,5	1,1
dez/22	2150	2364,5	214,5	540,9	292,9	1,8

Fonte: O Autor (2023)

Neste caso é possível observar um crescimento dos erros aritméticos comum e acumulado associados à previsão, indicando que a modelagem apresenta tendência em se distanciar dos valores reais da série temporal.

O *Tracking Signal* nos períodos observados se mantém dentro dos limites aceitáveis, indicando que o método se aplica e as previsões possuem boa acurácia. No entanto, seus valores também apresentam uma tendência de crescimento, o que significa que em um horizonte de tempo maior o método pode deixar de fornecer previsões assertivas para o produto 06801.

Agora focando no método de Holt, temos os resultados das previsões dispostas na Tabela 5 a seguir.

Tabela 5 – Previsão de demanda pelo método de Holt na série temporal do produto 06801.

Período	Demanda real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	2600	2232,7	-367,3	-367,3	367,3	-1,0
ago/22	2600	2147,4	-452,6	-819,9	409,9	-2,0
set/22	2500	2062,0	-438,0	-1257,8	419,3	-3,0
out/22	2400	1976,7	-423,3	-1681,1	420,3	-4,0
nov/22	2250	1891,4	-358,6	-2039,8	408,0	-5,0
dez/22	2150	1806,0	-344,0	-2383,8	397,3	-6,0

Fonte: O Autor (2023)

Na aplicação deste modelo pode-se observar que, apesar do crescimento do erro aritmético acumulado, existe uma tendência de queda nos valores do erro aritmético comum a partir de agosto de 2022, indicando que pouco a pouco os valores calculados pelo método estão se aproximando dos valores da série temporal. No entanto, o *Tracking Signal* associado é crescente e ficou fora do limite aceitável nas últimas duas previsões realizadas, indicando que a qualidade da previsão neste horizonte não é satisfatória e que o método não se aplica.

Ao analisar os resultados e respectivos monitoramentos das previsões pode-se afirmar que, no horizonte de seis meses estabelecido, o método de suavização exponencial simples foi o que melhor se adequou à série temporal do produto 06801.

4.3 00020 - QUEIJO AROMA IDENT NAT

A série de dados da demanda correspondente ao produto de código 00020, de nome comercial Queijo Aroma Ident Nat, está apresentada sob a forma de tabela no

Apêndice C e na Figura 11 a seguir.

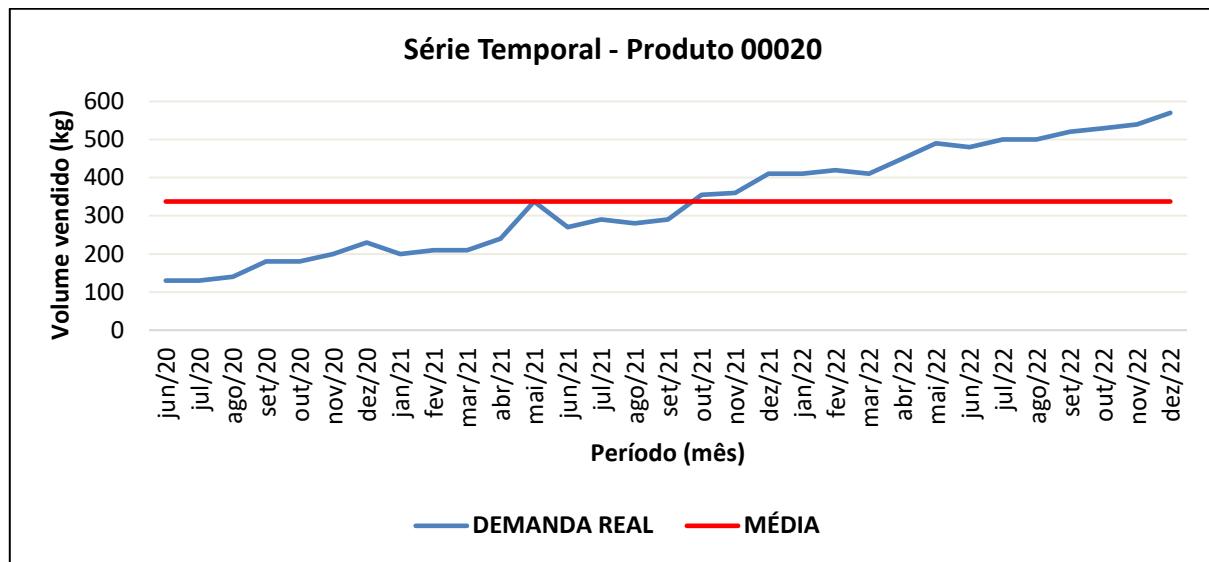


Figura 11 – Histórico de vendas do produto 00020.

Fonte: O Autor (2023)

Diferentemente do produto 06801, neste caso pode-se observar uma tendência de crescimento bem acentuada na demanda real, com a série ficando abaixo ou coincidindo com a média geral apenas entre junho de 2020 e outubro de 2021.

A aplicação dos quatro métodos de previsão já conhecidos pode ser observada na Figura 12 a seguir.

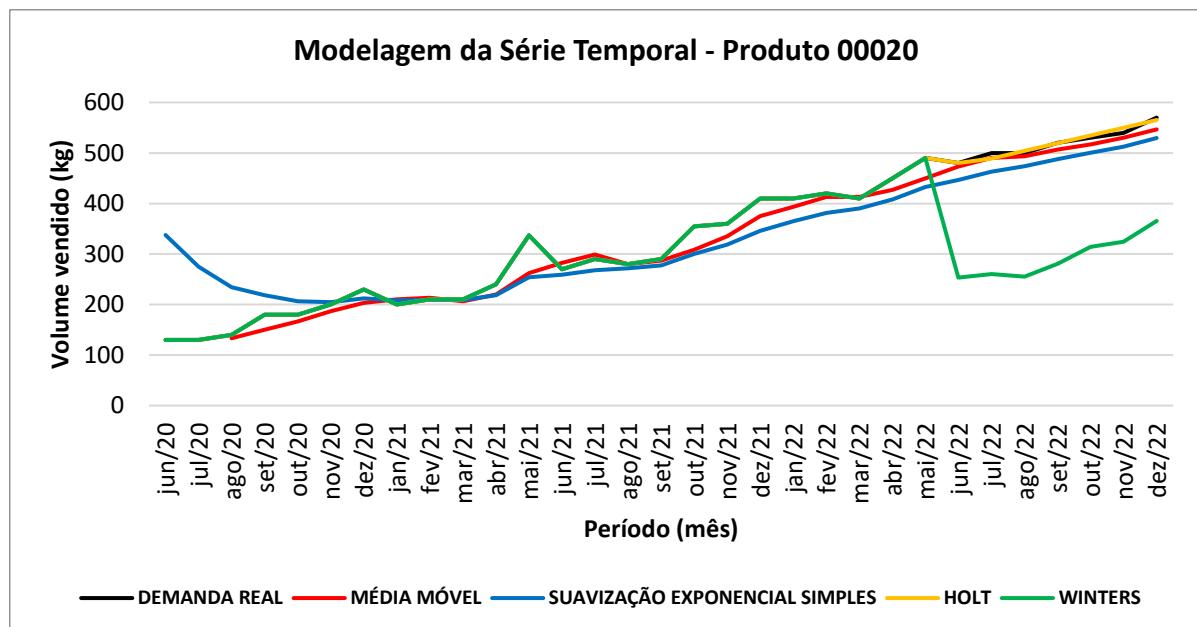


Figura 12 – Métodos quantitativos aplicados à série temporal do produto 00020.

Fonte: O Autor (2023)

Graficamente os modelos que se mantêm mais próximos do comportamento da série temporal, para este produto, são o de média móvel e o de Holt, portanto serão analisados. É esperado que a curva do modelo de média móvel esteja próxima da demanda real, pois como dito anteriormente, seus valores são médias dos valores da própria demanda real. Também é coerente a semelhança entre as curvas para o caso do modelo de Holt, pois o mesmo é aplicado geralmente em séries com tendências bem definidas.

Apesar de apresentar uma curva mais distante da demanda que os outros, o método de suavização exponencial simples será analisado por exibir comportamento de tendência semelhante e para estabelecer um comparativo entre este produto e o 06801, no qual os mesmos três métodos também foram discutidos.

A Tabela 6 a seguir contém o conjunto dos últimos seis valores previstos utilizando Média Móvel e seu monitoramento através do *Tracking Signal*.

Tabela 6 – Previsão de demanda usando Média Móvel Simples na série temporal do produto 00020.

Período	Demand real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	480	490,0	-10,0	-363,3	18,3	-19,8
ago/22	500	493,3	-6,7	-370,0	17,8	-20,7
set/22	500	506,7	-13,3	-383,3	17,7	-21,7
out/22	520	516,7	-13,3	-396,7	17,5	-22,7
nov/22	530	530,0	-10,0	-406,7	17,2	-23,6
dez/22	540	546,7	-23,3	-430,0	17,4	-24,6

Fonte: O Autor (2023)

Assim como na aplicação da Média Móvel Simples para o produto 06801, os erros aritméticos são pequenos e também oscilam de forma aleatória, entre -6,7kg e -

23,3kg. Como na aplicação deste método para o produto anterior, esse comportamento é esperado já que o modelo reage facilmente a *outliers* e tendências da série temporal. O erro aritmético acumulado apresenta tendência de crescimento, indicando que o modelo está se distanciando da série temporal.

O *Tracking Signal* esteve fora do limite em todos os períodos e apresenta valores crescentes que tendem a se distanciar ainda mais do intervalo de confiança. Dito isso, conclui-se que o modelo de Média Móvel não é o melhor método de previsão de demanda para este produto.

Para a Suavização Exponencial Simples foi adotada a mesma constante de suavização α igual a 0,3. Na Tabela 7 a seguir encontram-se os valores previstos pelo modelo e seus respectivos monitoramentos pelo *Tracking Signal*.

Tabela 7 – Previsão de demanda a partir de Suavização Exponencial Simples na série temporal do produto 00020.

Período	Demanda real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	480	462,8	-37,2	-84,9	43,7	-1,9
ago/22	500	474,0	-26,0	-111,0	43,1	-2,6
set/22	500	487,8	-32,2	-143,2	42,7	-3,4
out/22	520	500,4	-29,6	-172,7	42,2	-4,1
nov/22	530	512,3	-27,7	-200,4	41,7	-4,8
dez/22	540	529,6	-40,4	-240,8	41,7	-5,8

Fonte: O Autor (2023)

Aqui, assim como no produto 06801, se observa uma crescente no erro aritmético comum e acumulado associados à previsão, indicando que a modelagem está se distanciando da demanda real.

O *Tracking Signal* se manteve dentro do limite aceitável entre os períodos de

julho e setembro de 2022 e fora dele nos últimos três períodos, explicitando uma tendência de decrescimento. Esse comportamento indica que num horizonte de tempo mais longo os números do monitoramento deverão se afastar ainda mais do intervalo de confiança e por isso o método não é adequado para prever a demanda do produto.

Agora focando no método de Holt, tem-se os resultados das últimas previsões e seus respectivos monitoramentos dispostos a seguir na Tabela 8.

Tabela 8 – Previsão de demanda pelo método de Holt na série temporal do produto 00020.

Período	Demanda real (kg)	Previsão (kg)	Erro	Erro	Erro	Tracking
			aritmético (EAr)	aritmético acumulado (EArA)	médio absoluto (EMA)	Signal (EArA/EMA)
jul/22	480	489,1	-10,9	-10,9	10,9	-1,0
ago/22	500	504,4	4,4	-6,5	7,6	-0,9
set/22	500	519,6	-0,4	-6,9	5,2	-1,3
out/22	520	534,8	4,8	-2,1	5,1	-0,4
nov/22	530	550,0	10,0	8,0	6,1	1,3
dez/22	540	565,3	-4,7	3,2	5,9	0,6

Fonte: O Autor (2023)

Nesta previsão é possível observar que o erro aritmético associado é relativamente pequeno e oscila entre -10,9kg e 10kg, não apresentando nenhum tipo de tendência a se distanciar desta faixa. Os resultados apresentados no cálculo do monitoramento estão dentro do limite de ± 4 considerado pelo método, indicando que os erros podem ser desprezados e que os valores calculados estão dentro do padrão de qualidade aceitável.

Bem como esperado para uma série temporal com tendência bem definida, o método de Holt se apresentou como o mais adequado para prever a demanda do produto 00020.

4.4 06199 - QUEIJO COND PREP

A série de dados da demanda correspondente ao produto de código 06199, de nome comercial Queijo Cond Prep, está apresentada sob a forma de tabela no Apêndice C e na Figura 13 a seguir.

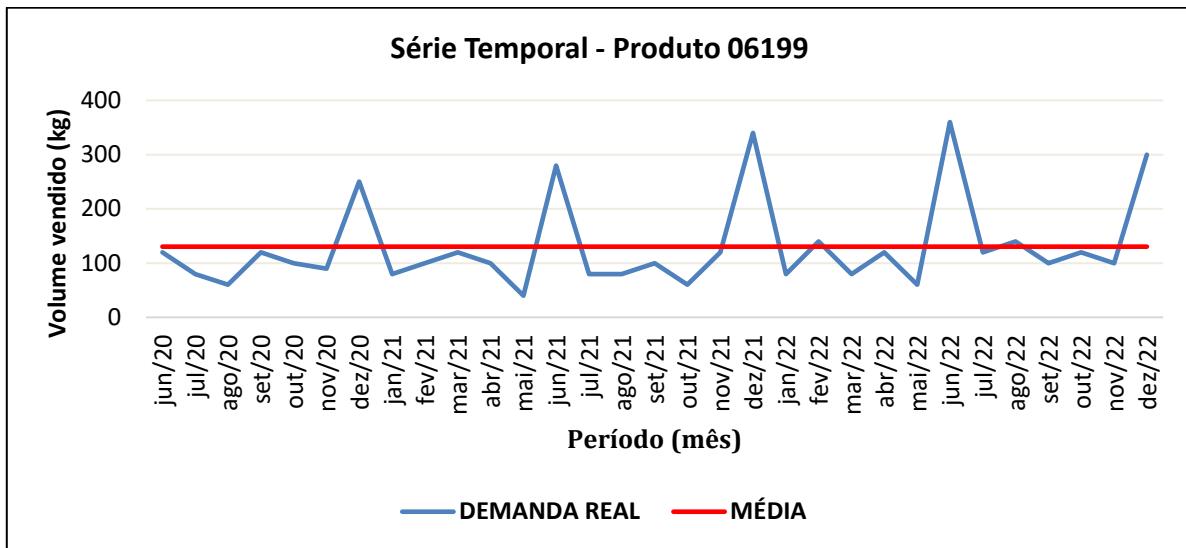


Figura 13 – Histórico de vendas do produto 06199.

Fonte: O Autor (2023)

Para este produto se observa uma demanda com série temporal que oscila em torno da média dos volumes vendidos em todos os meses. A média de 130kg é maior que 80% dos valores da série, e isso ocorre devido a presença de picos de venda nos meses de junho e dezembro de cada ano, que deslocam esse número para cima. Por ocorrerem regularmente a cada seis meses, esses eventos se configuram como sazonalidade. Portanto, a demanda dessa série se classifica como constante com sazonalidade.

A aplicação dos quatro métodos de previsão já citados pode ser observada na Figura 14 a seguir.

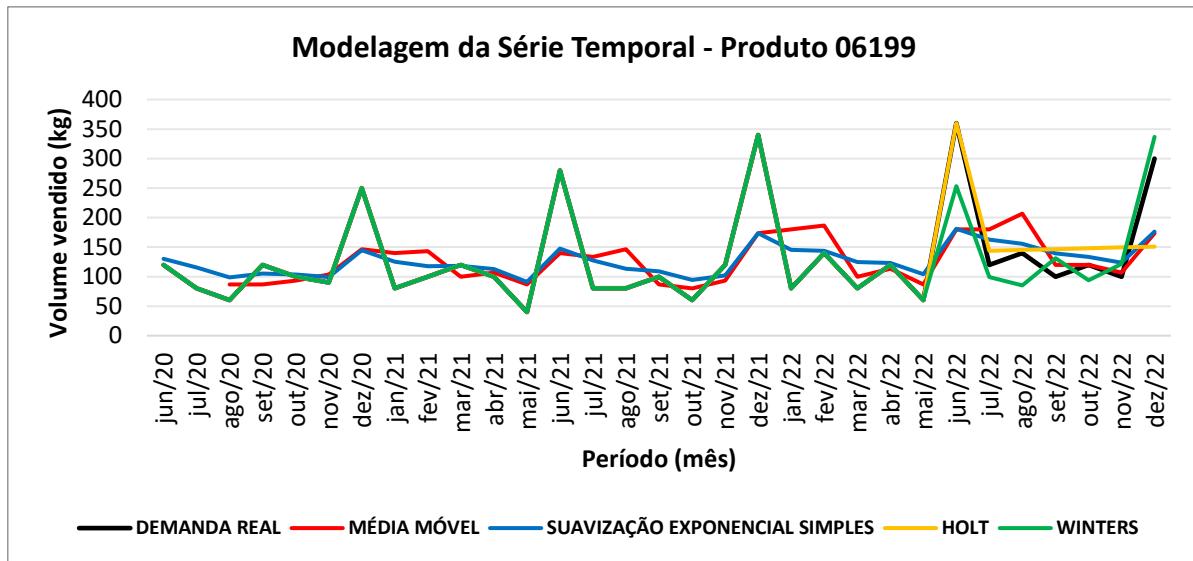


Figura 14 – Métodos quantitativos aplicados à série temporal do produto 06199.

Fonte: O Autor (2023)

Visualmente, o único modelo que apresenta uma curva semelhante a da série temporal e é capaz de replicar os picos de venda do histórico de demanda é o modelo de Winters. Esse resultado é esperado tendo em vista que esse método é o único que considera a sazonalidade como componente da demanda nos seus cálculos e prevê os picos seguintes.

A Tabela 9 a seguir contém o conjunto dos últimos seis valores previstos pelo modelo de Winters e seu monitoramento por meio do *Tracking Signal*.

Tabela 9 – Previsão de demanda pelo método de Winters na série temporal do produto 00020.

Período	Demanda real (kg)	Previsão (kg)	Erro aritmético (EAr)	Erro aritmético acumulado (EArA)	Erro médio absoluto (EMA)	Tracking Signal (EArA/EMA)
jul/22	120	99,2	20,8	-127,5	63,7	-2,0
ago/22	140	85,1	54,9	-182,4	60,8	-3,0
set/22	100	131,4	-31,4	-151,0	53,4	-2,8
out/22	120	94,0	26,0	-177,0	47,9	-3,7

nov/22	100	121,5	-21,5	-155,5	43,5	-3,6
dez/22	300	336,8	-36,8	-118,7	42,6	-2,8

Fonte: O Autor (2023)

Analizando os dados da previsão pode-se observar que o erro aritmético entre demanda real e previsão é considerável, variando entre -36,8kg e 54,9kg, porém ele oscila de forma aleatória, sem apresentar nenhum tipo de tendência.

Os números apresentados pelo *Tracking Signal* estão dentro do limite de ± 4 e não apresentam nenhum tipo de tendência, indicando que os erros associados podem ser desprezados, que os resultados obtidos pelo método estão dentro do padrão de qualidade aceitável e tendem a permanecer assim. Conclui-se, portanto, que o método de Winters é adequado para prever a demanda do produto 06199.

5. CONCLUSÃO

Neste trabalho buscou-se analisar o histórico e tipos de demanda de um grupo de quatro de produtos de uma indústria de aromas, elaborar previsões de venda para eles utilizando métodos quantitativos e comparar os resultados para definir quais os melhores métodos para cada produto.

No tocante ao produto 05623, de nome comercial Coco Aroma Artificial, identificou-se uma série temporal de demanda sem tendências, ciclos ou sazonalidades, e com valores oscilando em torno da média. Dadas essas características, o método quantitativo que apresentou as melhores previsões foi o de suavização exponencial simples, com um erro aritmético absoluto máximo de 5kg e um *Tracking Signal* médio de -0,13.

O produto 06801, de nome comercial Solução Amarelo Tartrazina, possui uma série com tendência decrescente. O método que se adequou melhor ao histórico de demanda foi o de suavização exponencial simples, que apesar de apresentar um erro aritmético acumulado crescente, esteve dentro dos limites aceitáveis do monitoramento de previsão, com um *Tracking Signal* médio de +0,37.

No caso do produto 00020, de nome comercial Queijo Aroma Ident Nat, a série temporal da demanda de vendas possui tendência crescente. O método que apresentou as melhores previsões foi o de suavização exponencial dupla de Holt, com um erro aritmético absoluto máximo de 10kg e um *Tracking Signal* médio de +0,15.

Por último, o produto 06691, de nome comercial Queijo Cond Prep, demonstra uma série com tendência constante e sazonalidade. O método quantitativo que calculou as previsões mais precisamente foi o sazonal multiplicativo de Winters, que apesar do erro aritmético absoluto máximo de 54,9kg, apresentou *Tracking Signal* médio de -2,98.

Os resultados das previsões elaboradas para cada produto saíram de acordo com o esperado pois os métodos se adequaram aos tipos de demanda que deveriam corresponder de acordo com a literatura.

Em conclusão, foi possível demonstrar com este trabalho que a análise de séries temporais e a aplicação de modelos quantitativos de previsão de demanda são ferramentas fundamentais para o planejamento e controle da produção, auxiliando para uma melhor gestão dos estoques e atendimento dos pedidos de venda com eficiência. Foi visto que essas técnicas podem ser valiosas para a indústria de aromas,

mas também podem ser aplicadas nas outras áreas e setores da economia, cedendo insumos para tomadas de decisão assertivas em um mercado cada vez mais competitivo e dinâmico.

REFERÊNCIAS

BOX, G.; LUCEÑO, A. **Statistical control by monitoring and feedback adjustment**, John Wiley. New York, 1997

CORRÊA, H.; GIANESI, I.; CAON, M. Planejamento, Programação e Controle da Produção. **MRP II / ERP: Conceitos, Uso e Implementação**. Editora Atlas. São Paulo, 1997.

ESTENDER, A. C.; SEQUEIRA, G. R.; SIQUEIRA, N. A. S.; CANDIDO, G. J. **A Importância do Planejamento e Controle de Produção**. VI Singep – Simpósio Internacional de Gestão de Projetos, Inovação e Sustentabilidade, 2017.

GARDNER, E. S. CUSUM vs smoothed-error forecast monitoring schemes: Some simulation results. **Journal of the Operational Research Society**, p. 43-47, 1985.

GONZAGA, S. T. **Curso de Séries Temporais**. Instituto Brasileiro de Pesquisa e Análise de Dados (IBPAD). Brasília, 2017.

Disponível em: <<https://s3.ibpad.com.br/seriestemporais/>>

GOUVEIA, F. **Indústria de alimentos: no caminho da inovação e de novos produtos**. Inovação Uniemp, v.2, n.5. Campinas, 2006.

GUTIERREZ, J. L. C. **Monitoring of the Corumbá - i Dam Instrumentation Neural Networks and the Box & Jenkins null Models**. Pontifícia Universidade Católica do Rio de Janeiro, 2003.

Disponível em: <http://www.maxwell.vrac.puc-rio.br/4244/4244_5.PDF>. Acesso em 01 de abril de 2023.

PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. Porto Alegre: UFRGS, 2000. Dissertação (Mestrado em Engenharia de Produção), Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, 2000.

PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda Técnicas e Estudo de Caso**. Revista PRODUÇÃO, v.11, n. 1. Porto Alegre, 2001.

PINTO, W. O. **Previsão de séries temporais com redes neurais artificiais aplicada à demanda.** Monografia (Bacharel em Sistemas de Informação) - Departamento de Ciências Exatas, Centro Universitário do Leste de Minas Gerais. Coronel Fabriciano, 2009.

PONTES, André. **Aprenda do ZERO qual a relação entre WCM e TPM nas Indústrias.** LinkedIn, 2018.

Disponível em: <<https://www.linkedin.com/pulse/aprenda-do-zero-qual-rela%C3%A7%C3%A3o-entre-wcm-e-tpm-nas-andr%C3%A9-pontes/?originalSubdomain=pt>>. Acesso em: 02 de fevereiro de 2023.

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

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting – methods and applications**, John Wiley, 3^a ed. New York, 1998.

MCCLAIN, J. O.; THOMAS, L. J. Using false alarms to improve forecast accuracy. **European journal of operational research**, v. 55, n. 2, p. 218-227, 1991.

MEDEIRO, N. C. O. **Predição da disponibilidade de recursos computacionais a partir do uso de médias móveis em séries temporais.** Trabalho de Conclusão de Curso (Bacharel em Ciência da Computação), Universidade Tecnológica Federal do Paraná. Ponta Grossa, p. 23, 2021.

MENTZER, f. T & COX fr., J. E. **Familiarity, application, and performance of sales forecasting techniques.** Journal of Forecasting, v. 3, p. 27-37, 1997.

MORETTIN, P.A.; TOLOI, C.M. **Previsão de séries temporais.** 2^a ed, Atual Editora. São Paulo, 1987.

TAMAKI, D. M. C. **Estudo dos métodos de detecção de mudanças em modelos de previsão de séries temporais.** Tese de Mestrado em Ciências de Engenharia de Produção, Universidade Federal de Itajubá. Itajubá, p. 21, 2016.

TRIGG, D. W. **Monitoring a forecasting system.** Taylor & Francis, Ltd., v. 15, n. 3, p. 271-274, 1964.

YAMASAKI, F. Y. **Aplicação da tecnologia de spray-drying em encapsulação de aromas na indústria de alimentos.** Trabalho de Conclusão de Curso (Bacharel em Farmácia) - Instituto de Ciências Ambientais, Químicas e Farmacêuticas, Universidade Federal de São Paulo. Diadema, p. 9, 2020.

APÊNDICES

APÊNDICE A – DEMANDA REAL E PREVISÕES PARA O PRODUTO 05623

Períodos	Demanda real (kg)	Média Móvel Simples (kg)	Suavização Exponencial Simples (kg)	Holt (kg)	Winters (kg)
jun/20	100		95,6		
jul/20	100		97,0		
ago/20	120	106,7	103,9		
set/20	110	110,0	105,7		
out/20	90	106,7	101,0		
nov/20	100	100,0	100,7		
dez/20	90	93,3	97,5		
jan/21	90	93,3	95,2		
fev/21	90	90,0	93,7		
mar/21	110	96,7	98,6		
abr/21	90	96,7	96,0		
mai/21	100	100,0	97,2		
jun/21	110	100,0	101,0		
jul/21	90	100,0	97,7		
ago/21	80	93,3	92,4		
set/21	100	90,0	94,7		
out/21	90	90,0	93,3		
nov/21	90	93,3	92,3		
dez/21	90	90,0	91,6		
jan/22	100	93,3	94,1		
fev/22	85	91,7	91,4		
mar/22	95	93,3	92,5		
abr/22	90	90,0	91,7		
mai/22	95	93,3	92,7		

jun/22	90	91,7	91,9		133,0
jul/22	95	93,3	92,8	86,5	117,8
ago/22	100	95,0	95,0	85,8	121,6
set/22	95	96,7	95,0	85,1	125,4
out/22	90	95,0	93,5	84,3	105,7
nov/22	100	95,0	95,4	83,6	110,0
dez/22	90	93,3	93,8	82,9	102,8

APÊNDICE B – DEMANDA REAL E PREVISÕES PARA O PRODUTO 06801

Períodos	Demanda real (kg)	Média Móvel Simples (kg)	Suavização Exponencial Simples (kg)	Holt (kg)	Winters (kg)
jun/20	4500		3167,4		
jul/20	4500		3567,2		
ago/20	4400	4466,7	3817,0		
set/20	4800	4566,7	4111,9		
out/20	3600	4266,7	3958,3		
nov/20	3400	3933,3	3790,8		
dez/20	4240	3746,7	3925,6		
jan/21	3800	3813,3	3887,9		
fev/21	3500	3846,7	3771,5		
mar/21	3600	3633,3	3720,1		
abr/21	3500	3533,3	3654,1		
mai/21	3700	3600,0	3667,8		
jun/21	2700	3300,0	3377,5		
jul/21	3000	3133,3	3264,2		
ago/21	2500	2733,3	3035,0		
set/21	3200	2900,0	3084,5		
out/21	2800	2833,3	2999,1		
nov/21	3100	3033,3	3029,4		
dez/21	2800	2900,0	2960,6		
jan/22	2800	2900,0	2912,4		
fev/22	3000	2866,7	2938,7		
mar/22	2200	2666,7	2717,1		
abr/22	2500	2566,7	2652,0		
mai/22	2850	2516,7	2711,4		

jun/22	2700	2683,3	2708,0	4559,9
jul/22	2600	2716,7	2675,6	2232,7
ago/22	2600	2633,3	2652,9	2147,4
set/22	2500	2566,7	2607,0	2062,0
out/22	2400	2500,0	2544,9	1976,7
nov/22	2250	2383,3	2456,4	1891,4
dez/22	2150	2266,7	2364,5	1806,0

APÊNDICE C – DEMANDA REAL E PREVISÕES PARA O PRODUTO 00020

Períodos	Demanda real (kg)	Média Móvel Simples (kg)	Suavização Exponencial Simples (kg)	Holt (kg)	Winters (kg)
jun/20	130		337,5		
jul/20	130		275,2		
ago/20	140	133,3	234,7		
set/20	180	150,0	218,3		
out/20	180	166,7	206,8		
nov/20	200	186,7	204,8		
dez/20	230	203,3	212,3		
jan/21	200	210,0	208,6		
fev/21	210	213,3	209,0		
mar/21	210	206,7	209,3		
abr/21	240	220,0	218,5		
mai/21	337	262,3	254,1		
jun/21	270	282,3	258,8		
jul/21	290	299,0	268,2		
ago/21	280	280,0	271,7		
set/21	290	286,7	277,2		
out/21	355	308,3	300,6		
nov/21	360	335,0	318,4		
dez/21	410	375,0	345,9		
jan/22	410	393,3	365,1		
fev/22	420	413,3	381,6		
mar/22	410	413,3	390,1		
abr/22	450	426,7	408,1		
mai/22	490	450,0	432,7		

jun/22	480	473,3	446,9		253,3
jul/22	500	490,0	462,8	489,1	260,4
ago/22	500	493,3	474,0	504,4	255,4
set/22	520	506,7	487,8	519,6	280,7
out/22	530	516,7	500,4	534,8	314,3
nov/22	540	530,0	512,3	550,0	324,1
dez/22	570	546,7	529,6	565,3	365,3

APÊNDICE D –DEMANDA REAL E PREVISÕES PARA O PRODUTO 06199

Períodos	Demanda real (kg)	Média Móvel Simples (kg)	Suavização Exponencial Simples (kg)	Holt (kg)	Winters (kg)
jun/20	120		130,3		
jul/20	80		115,2		
ago/20	60	86,7	98,7		
set/20	120	86,7	105,1		
out/20	100	93,3	103,5		
nov/20	90	103,3	99,5		
dez/20	250	146,7	144,6		
jan/21	80	140,0	125,2		
fev/21	100	143,3	117,7		
mar/21	120	100,0	118,4		
abr/21	100	106,7	112,9		
mai/21	40	86,7	91,0		
jun/21	280	140,0	147,7		
jul/21	80	133,3	127,4		
ago/21	80	146,7	113,2		
set/21	100	86,7	109,2		
out/21	60	80,0	94,5		
nov/21	120	93,3	102,1		
dez/21	340	173,3	173,5		
jan/22	80	180,0	145,4		
fev/22	140	186,7	143,8		
mar/22	80	100,0	124,7		
abr/22	120	113,3	123,3		
mai/22	60	86,7	104,3		

jun/22	360	180,0	181,0		253,3
jul/22	120	180,0	162,7	143,9	99,2
ago/22	140	206,7	155,9	145,3	85,1
set/22	100	120,0	139,1	146,7	131,4
out/22	120	120,0	133,4	148,0	94,0
nov/22	100	106,7	123,4	149,4	121,5
dez/22	300	173,3	176,4	150,8	336,8
