



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

IA nas Engenharias

29 nov. a 01 de dezembro 2023

Análise de Séries Temporais na Previsão de Demanda: Um Estudo de Caso de uma Empresa Brasileira de Bebidas

Felipe Augusto Santos Borges

Programa de Pós-Graduação em Engenharia de Produção – UFPR

Lorayne Veri

Programa de Pós-Graduação em Engenharia de Produção – UFPR

Mariana Kleina

Programa de Pós-Graduação em Engenharia de Produção – UFPR

Paola Andrea Rico Belalcazar

Programa de Pós-Graduação em Engenharia de Produção – UFPR

Marcell Mariano Corrêa Maceno

Programa de Pós-Graduação em Engenharia de Produção – UFPR

Resumo: Este estudo aprofunda-se na análise de séries temporais, enfatizando sua importância na predição de demanda para otimização de processos em empresas. A pesquisa emprega uma série temporal de pedidos diários de uma empresa brasileira de bebidas alcoólicas, comercializadas via aplicativo. As séries temporais, ricas em informações históricas, permitem avaliar a performance passada e projetar futuros comportamentos. Utilizando-se da linguagem R, a investigação avaliou conceitos como estacionariedade, tendência e sazonalidade, com o auxílio dos testes ADF, KPSS e Mann-Kendall. Ao identificar a ausência de tendência e a presença de sazonalidade, a pesquisa selecionou os métodos ARIMA e Suavização Exponencial Simples com ajuste sazonal para previsão. A análise, mais do que puramente técnica, oferece uma intersecção entre teoria e prática, destacando a relevância da previsão precisa para tomadas de decisão eficazes. O estudo concluiu que a Suavização Exponencial Simples com ajuste sazonal proporciona a melhor previsão para a série em questão, ilustrando a aplicabilidade prática da teoria de séries temporais no contexto do mercado brasileiro.

Palavras-chave: Séries temporais, Previsão de demanda, Estacionariedade, ARIMA, Suavização Exponencial Simples.

Time Series Analysis in Demand Forecasting: A Case Study of a Brazilian Beverage Company

Abstract: This study delves into time series analysis, emphasizing its importance in demand prediction to process optimization in businesses. The research uses a time series of daily orders from a Brazilian alcoholic beverage company, sold via an app. Time series, rich in historical information, allow for the evaluation of past performance and projection of future behaviors. Employing the R language, the investigation assessed concepts like stationarity, trend, and seasonality, aided by ADF, KPSS, and Mann-Kendall tests. Upon identifying the absence of a trend and the presence of seasonality, the research selected the ARIMA method and Seasonally Adjusted

Exponential Smoothing for forecasting. The analysis, beyond being purely technical, offers an intersection between theory and practice, highlighting the relevance of accurate forecasting for effective decision-making. The study concluded that Seasonally Adjusted Exponential Smoothing provides the best forecast for the series in question, illustrating the practical applicability of time series theory in the Brazilian market context.

Keywords: Time series analysis, Demand forecasting, Stationarity, ARIMA, Exponential Smoothing.

1. Introdução

O Planejamento e Controle da Produção (PCP) em uma organização é vital, pois parte de sua responsabilidade é antecipar o período de recebimento e despacho de mercadorias, tempo de fabricação e operacionalização. Isso assegura que a companhia fabrique seu produto de forma eficiente e de alta qualidade, entregando-o no prazo acordado com o cliente. Cabe a essa área estabelecer também sequências operacionais, organizar métodos e, se necessário, os ajustar (TUBINO, 1997).

O PCP apresenta instrumentos para antecipar a demanda, fornecendo à empresa dados valiosos sobre seu mercado e seu comportamento. Isso capacita os gestores a fazerem escolhas fundamentadas e acuradas, respaldadas por informações palpáveis, como a evolução do mercado ou a ampliação de uma atividade comercial (TUBINO, 1997). Uma acurada antecipação da demanda é crucial para um eficiente planejamento de estoque, reduzindo potenciais riscos de perdas, excessos e desperdícios. No cenário atual, com a crescente ampliação do volume de dados e seu impacto em várias áreas, estas antecipações tornam-se ainda mais essenciais, pois contribuem para decisões empresariais (CORTEZ, 2002).

Conforme destacado por Tubino (1997), antecipar a demanda é crucial para a tomada de decisões em qualquer corporação. Estimar a demanda com a menor margem de erro possibilita à empresa se organizar em termos de orçamento, estoque, capacidade e muitos outros recursos, incluindo recursos humanos. Assim, com base na antecipação da demanda, uma empresa pode estrategicamente se posicionar para considerar a introdução de novos produtos, avaliar seu crescimento em relação aos rivais, e promover campanhas promocionais, entre outras ações.

Este estudo se concentrou em aplicar técnicas de antecipação da demanda, analisando dois métodos de projeção quantitativa (método de suavização exponencial simples e ARIMA) com base nos dados de pedidos diários (de janeiro a agosto de 2023) de uma companhia brasileira que vende on-line diversos tipos de bebidas alcoólicas por meio de um aplicativo exclusivo para *smartphones*.

O método de suavização exponencial simples, pertencente às técnicas de séries temporais, é eficaz para identificar tendências e modelos em dados ao longo do tempo. Por outro lado, o modelo ARIMA opera sob o pressuposto de que as flutuações na série podem ser expressas por meio da combinação de três componentes: autorregressivo (AR), de integração (I) e médias móveis (MA). Ao modelar uma série específica, pode-se usar todos os três ou apenas um subconjunto deles. Um aspecto importante é que os dados em uma série temporal são fortemente influenciados por dados anteriores, podendo cada ponto ser explicado por registros antecedentes (PELLEGRINI, 2000). A abordagem enfoca a relação temporal entre os pontos de dados e, por serem baseados em uma única série temporal, são denominados modelos univariados (PELLEGRINI, 2000). Em outras palavras, esses modelos utilizam uma única variável e a explicam por meio de seus registros prévios, impactos anteriores e erros ou resíduos passados. Ao avaliar esses métodos, este estudo busca não só projetar a demanda futura, mas também determinar a margem de erro em cada abordagem.

2. Referencial Teórico

As séries temporais são definidas como dados que se distribuem uniformemente ao longo de períodos determinados, como diariamente, semanalmente, mensalmente ou até anualmente. Tais dados permitem fazer previsões de valores futuros com base em registros passados ou históricos. Heizer e Render (2001) salientam a importância de desmembrar esses dados em componentes, tais como tendência e sazonalidade, para que sejam realizadas projeções mais assertivas.

Conforme as observações de Heizer e Render (2001), a criação de modelos de previsão se desdobra em sete etapas cruciais: determinar o objetivo da previsão, identificar os fatores a serem projetados, estabelecer o intervalo da previsão, selecionar o modelo de previsão apropriado, reunir dados passados, realizar a previsão e, finalmente, verificar a acurácia dos resultados. Os autores também reforçam a ideia de que previsões raramente são absolutamente exatas, uma vez que existem variáveis externas, frequentemente inesperadas ou incontrolláveis, que podem alterar os resultados projetados.

2.1 Técnicas de previsão utilizadas

2.1.1 Suavização Exponencial Simples

Na Suavização Exponencial Simples (SES) a ideia geral é a de que as observações mais recentes possuem maior relevância que as previsões mais antigas, esta técnica melhor atua em séries temporais que se mantêm constante sobre um nível médio (MAKRIDAKIS *et al.*, 1998). Partindo do princípio que a demanda gira em torno de uma demanda base constante, sendo corrigida por uma constante à medida que novos dados são incorporados a série histórica, de modo que os dados mais recentes recebem maiores ponderações. O uso deste modelo é adequado para séries que não possuem tendência e sazonalidade. A constante alfa (para o nível) é o parâmetro de suavização do método, podendo variar entre 0 e 1 (ACKERMANN; SELLITTO, 2022). A formulação da SES é dada por:

$$P_t = \alpha R_{t-1} + (1 - \alpha)P_{t-1}$$

Onde, P_t é a previsão para o período t , V_{t-1} é o valor real no período $t - 1$, e α é a constante de suavização e deve estar no intervalo entre $[0, 1]$.

Para séries temporais que não apresentam tendência e apresentam sazonalidade, o método de Suavização Exponencial Simples ainda pode ser aplicado (ACKERMANN; SELLITTO, 2022). Primeiramente, retira-se a sazonalidade da série, por meio de subtrações ou divisões (a depender se a sazonalidade é aditiva ou multiplicativa, respectivamente) do fator sazonal, aplica-se Suavização Exponencial Simples, e por último, incorpora-se o fator sazonal às previsões, por meio de adições ou multiplicações (a depender se a sazonalidade é aditiva ou multiplicativa, respectivamente).

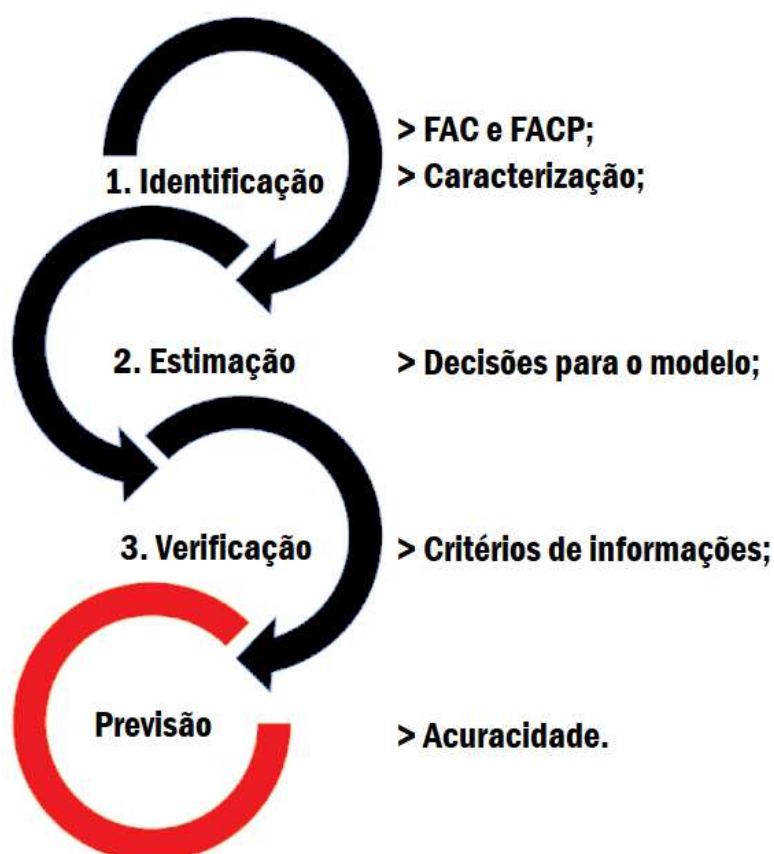
2.1.2 ARIMA

Os padrões comuns dos modelos se caracterizam como ARIMA (sigla do termo em inglês *Auto Regressive Integrated Moving Average*, que traduzindo significa Média Móvel Integrada Auto-regressiva) de ordem p , d e q . Onde p representa o processo autorregressivo não sazonal integrado ao modelo, indicando o intervalo entre a observação atual e os valores precedentes; d denota o grau de diferenciação; e q reflete a ordem da componente da média móvel.

Esses modelos ARIMA são designados para séries temporais que são estacionárias. Paralelamente, os modelos SARIMA se apresentam, que incluem uma dimensão sazonal (MAKRIDAKIS *et al.*, 1998). Se a série em análise for não estacionária, é essencial realizar sua diferenciação para que o modelo ARIMA seja aplicável (PELLEGRINI, 2000).

Segundo Morettin e Toloí (2006), a metodologia Box-Jenkins propõe um ajuste dos modelos ARIMA a um conjunto determinado de dados e este método opera de forma iterativa, com uma análise focada diretamente nas informações da série. No início, ocorre a fase de identificação, que observa as funções de autocorrelação (FAC) e as de autocorrelações parciais (FACP), visando detectar deslocamentos temporais com valores significativos nestas funções. O principal objetivo é identificar aspectos relacionados à estacionariedade e sazonalidade. Nos correlogramas de FAC e FACP, um decaimento exponencial sugere estacionariedade, bem como senoides que se reduzem gradualmente. Por outro lado, outros tipos de decaimento sugerem não estacionariedade. Nas etapas subsequentes de estimação e validação, os deslocamentos destacados nos correlogramas de FAC e FACP fornecem os valores p e q para o modelo ARIMA. Assim, combinações possíveis destes valores são examinadas. O modelo que oferecer a melhor performance, de acordo com critérios informativos específicos, é selecionado para estimar a série temporal. Quando os resíduos deste modelo se assemelham a um ruído branco, o ajuste é considerado satisfatório. Finalmente, o modelo é utilizado na fase de previsão para antecipar futuras observações da série temporal. A Figura 1 apresenta todo este ciclo iterativo descrito acima com as respectivas etapas.

Figura 1 – Abordagem Box-Jenkins Ciclo Iterativo



Fonte: Os autores (2023) baseado Morettin e Toloí (2006)

Os modelos ARIMA também são capazes de modelar uma ampla gama de dados sazonais. Quando há padrões senoidais na FAC a série é considerada sazonal. Se padrões senoidais estiverem ausentes, a série é classificada como não sazonal. Um modelo ARIMA sazonal

é formado pela inclusão de termos sazonais adicionais, na forma $ARIMA(p,d,q)(P,D,Q)_m$, onde o segundo componente faz referência à parte sazonal e m significa o número de períodos por estação.

2.2 Critério para escolha do modelo

A utilização do modelo escolhido para antecipar futuras observações pode ter sua eficácia alterada com base na sua interação com a série temporal em estudo (PELLEGRINI, 2000).

Os métodos foram comparados utilizando o valor calculado da Raiz do Erro Médio Quadrático, comumente referida como REMQ ou RMSE (a partir da expressão em inglês *Root Mean Square Error*), expressa pela seguinte equação:

$$REMQ = \sqrt{\frac{\sum_{t=1}^n e_t^2}{n}}$$

Em que n representa a quantidade de observações e e_t é o erro entre o valor real e o valor previsto no instante de tempo t .

Esta medida representa a raiz quadrada da média do somatório dos erros ao quadrado, e quanto mais próxima de zero melhor.

3. Metodologia

Para o desenvolvimento deste trabalho, utilizou-se uma base nos dados de pedidos diários, de uma companhia brasileira que vende on-line, diversos tipos de bebidas alcoólicas por meio de um aplicativo exclusivo para *smartphones*. Na Tabela 1, apresenta-se uma breve descrição dos dados analisados.

Tabela 1 – Variáveis da série temporal

Nome da variável	Descrição	Tipo
<i>Dia</i>	Data referente ao dia que se recebeu o pedido	Data no formato dia/mês/ano
<i>Pedidos</i>	Dado do número de pedidos gerados no determinado dia	Número real entre 41.193 e 381.382

Fonte: Os autores (2023) - Base de dados

O estudo foi desenvolvido no software *R*, utilizando os dados do período de 01 de janeiro de 2023 até 30 de agosto de 2023, com 242 registros históricos diários, e que por sua vez, o estudo dividiu-se em três etapas representadas na Figura 2.

Figura 2 – Etapas da pesquisa



Fonte: Os autores (2023)

3.1 Comportamento da série temporal

O primeiro elemento avaliado foi a estacionariedade da série temporal. Para essa finalidade, dois testes estatísticos foram aplicados. Primeiramente, o Teste Augmented Dickey-Fuller (ADF) foi empregado, o qual propõe a hipótese nula de que a série não é estacionária, sendo aceita quando o p-valor supera um valor crítico (por exemplo, 0,05) (MIELKE; VILLAS BOAS, 2022).

Em contraste, o teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS) assume como hipótese nula a estacionariedade da série, que é aceita quando o p-valor excede um valor crítico (0,05) (ALBERTO *et al.*, 2022).

Adicionalmente, para determinar a presença de tendência nos dados, recorreu-se ao teste de Mann-Kendall (MK). Se o p-valor for inferior a um valor crítico (por exemplo, 0,05), conclui-se que a série possui uma tendência (ARAÚJO *et al.*, 2015). Por último, a sazonalidade da série temporal foi avaliada por meio de visualizações gráficas. De acordo com (ACKERMANN; SELLITTO, 2022), a sazonalidade se caracteriza por padrões consistentes que se repetem em intervalos de tempo específicos.

Na Tabela 2, são apresentados os códigos em linguagem R dedicados à análise de cada aspecto da série temporal em questão.

Tabela 2 – Código comportamento série temporal no *software* R

Componente	Teste	Código
Estacionariedade	ADF	<code>adf.test(Pedidos\$Pedidos)</code>
	KPSS	<code>kpss.test(Pedidos\$Pedidos)</code>
Tendência	MK	<code>mk.test(Pedidos\$Pedidos)</code>

Fonte: Os autores (2023)

3.2 Comparação gráfica dos métodos de previsão

Após a caracterização da série temporal foram escolhidos os métodos de previsão a serem analisados. Conforme os resultados obtidos do comportamento dos dados definiu-se que, a ARIMA e a Suavização Exponencial Simples com correção de sazonalidade são os métodos que melhor poderiam se ajustar à série temporal, por causa da sazonalidade identificada.

Em seguida, os dois métodos selecionados foram aplicados por meio do *software* R e os gráficos foram plotados para realizar a comparação. Apresentam-se os códigos usados na Figura 3.

Cabe mencionar que, prévio ao desenvolvimento do método de Suavização Exponencial Simples realizou-se uma correção da sazonalidade aditiva considerando que não existe uma variação na amplitude da sazonalidade presente nos dados (ALVES *et al.*, 2019; ACKERMANN; SELLITTO, 2022).

Figura 3 – Códigos do R dos dois métodos

```
library(forecast)
#Arima
model<-auto.arima(Pedidos_ts)
model<-model$fitted

#Correção sazonalidade
Pedidos_ts <-ts(Pedidos$Pedidos,start=c(2023,1),frequency = 7)
Pedidos_ts_decom<-decompose(Pedidos_ts)
Pedidos_sa<- seasadj(Pedidos_ts_decom)
fator<- ts(Pedidos_ts_decom$seasonal,start = c(2023,1),frequency = 7)

# suavização exponencial simples
Pses<-ses(y=Pedidos_sa,h=1,initial = "optimal")
Pses<-Pses$fitted
Pses_adj<-Pses+fator
```

Fonte: Os autores (2023)

3.3 Comparação de REMQ dos métodos de previsão

Em conclusão, para assegurar uma clara distinção de qual método se alinha mais precisamente com os dados, uma avaliação foi proposta baseada no erro gerado pelos resultados de cada técnica em estudo. O critério de erro escolhido foi a Raiz do Erro Médio Quadrático (REMQ).

4. Resultados

4.1 Comportamento da série temporal

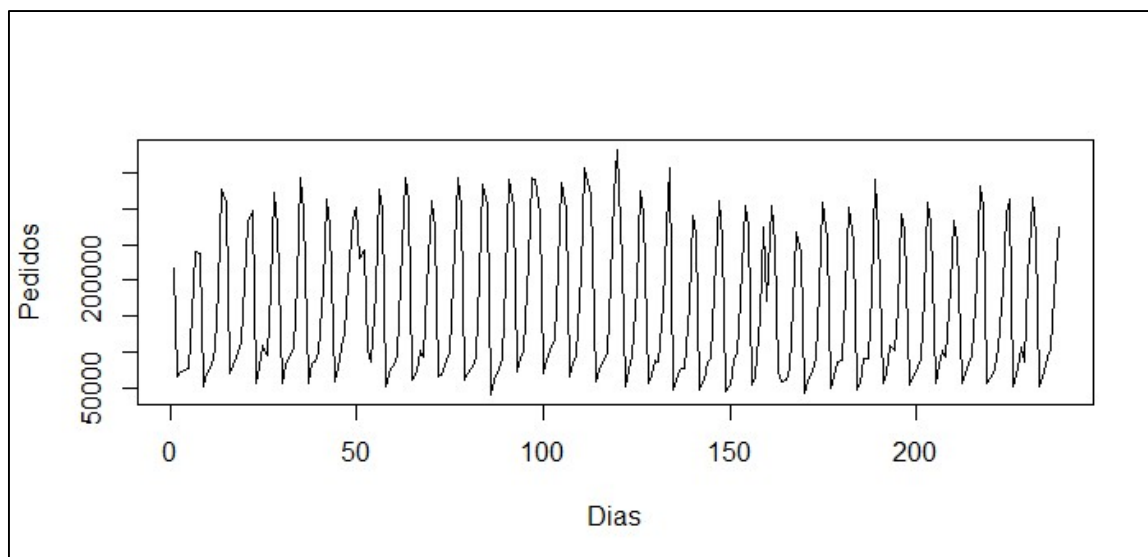
A fim de compreender o comportamento dos dados da série, conduziram-se testes para investigar características como a estacionariedade e a tendência. Além disso, mediante a visualização gráfica da série temporal, concluiu-se a presença de sazonalidade nos dados.

Tabela 3 – Comportamento da série temporal

Componente	Teste	p-valor
Estacionariedade	ADF	0,05631
	KPSS	0,01
Tendência	MK	0,2729

Fonte: Os autores (2023)

Figura 4 – Série temporal



Fonte: Os autores (2023)

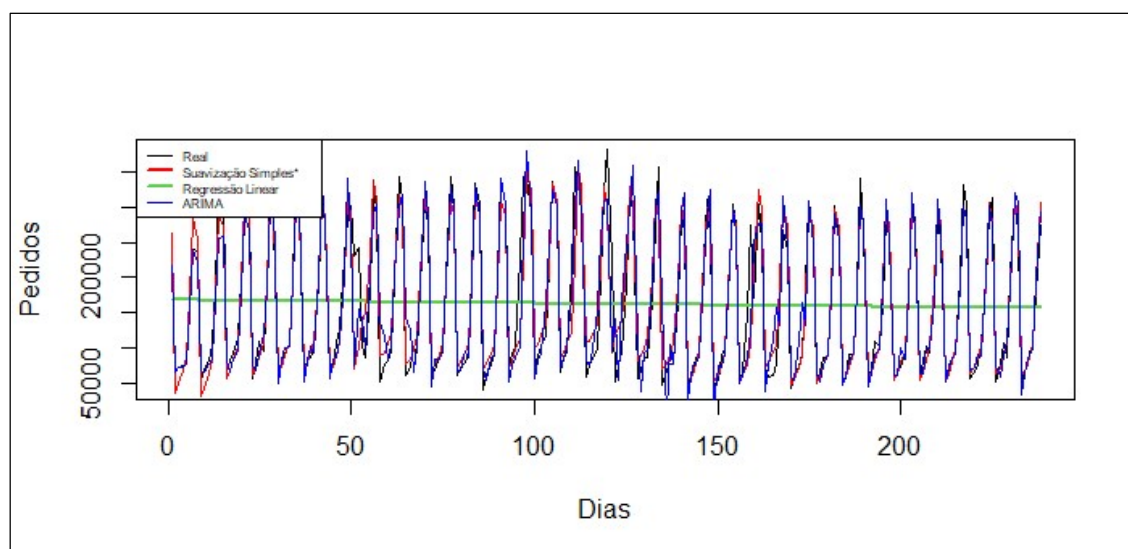
De acordo com os dados apresentados na Tabela 3, é possível concluir que a série temporal não possui uma tendência, visto que o p-valor é maior ao valor crítico (0,05). A estacionariedade não está presente, conforme indicado pelos resultados dos testes ADF e KPSS.

Além disso, com base na Figura 4, observa-se que o gráfico apresenta padrões ondulatórios ou picos em intervalos de tempo específicos, levando à conclusão de que os dados têm sazonalidade (LIMA *et al.*, 2019).

4.2 Comparação gráfica dos métodos de previsão

Após a caracterização da série temporal, foram aplicados os métodos de previsão selecionados no software *R*. Os resultados são apresentados na Figura 5, onde é possível observar que os métodos, visivelmente, não denotam uma diferença significativa entre si e com os dados originais da série temporal.

Figura 5 – Comparação gráfica dos métodos



Cabe mencionar que os parâmetros da Suavização Exponencial Simples com correção da sazonalidade são escolhidos por meio de uma otimização da função *ses()* do software R, utilizando o parâmetro “initial” igual a “optimal”. Sendo o valor obtido da constante $\alpha = 1,414251e^{-0}$. Por outro lado, o modelo ajustou um ARIMA ($p = 1, d = 0, q = 1$) ($P = 1, D = 1, Q = 0$)₇.

4.3 Comparação de REMQ dos métodos de previsão

Para obter uma comparação mais clara de qual dos métodos de previsão estabelecidos ajustou-se melhor a série temporal, foi calculada a Raiz do Erro Médio Quadrático. Encontram-se os resultados na Tabela 5.

Tabela 4 – Erros dos métodos de previsão

Método	REMQ
ARIMA	34.128,50
Suavização Exponencial Simples com correção da sazonalidade	32.499,11

Fonte: Os autores (2023)

Identificou-se que o método com melhor previsão da série temporal é a Suavização Exponencial Simples com correção da sazonalidade tem um menor REMQ. Cabe mencionar que assim como na análise gráfica, é possível determinar que o resultado entre os dois métodos não apresenta uma diferença significativa.

5. Conclusões

Em um mercado cada vez mais dinâmico e competitivo, a capacidade de antecipar demandas e otimizar processos torna-se um diferencial estratégico para as empresas. Uma previsão precisa não apenas contribui para a eficiência operacional, reduzindo custos e evitando desperdícios, mas também possibilita que organizações estejam preparadas para atender às expectativas de seus clientes. As séries temporais, com sua volumetria de dados históricas, surgem como ferramentas valiosas nesse cenário, fornecendo informações cruciais para que as decisões empresariais estejam embasadas e sejam assertivas.

A série temporal analisada demonstrou uma sazonalidade, o que favoreceu a aplicação de técnicas de previsão como a Suavização Exponencial Simples com ajuste sazonal e o método ARIMA. Para estabelecer qual técnica se alinhava melhor aos dados, dois métodos de comparação foram empregados. O primeiro se deu por meio da análise gráfica, na qual não foi discernível um método superior. Já o segundo método se pautou na comparação dos erros oriundos dos resultados de cada técnica. Neste contexto, a Suavização Exponencial Simples com ajuste sazonal destacou-se, exibindo o menor REMQ.

Referências

ACKERMANN, A. E. F.; SELLITTO, M. A. (2022). Métodos de previsão de demanda: uma revisão da literatura. *Innovar*, 32(85), 83–99. <https://doi.org/10.15446/innovar.v32n85.100979>.

ALBERTO, H., CASAS, M.; OROZCO, F. L. (2022). **Uso de series temporales para el análisis y predicción de consumo de materia prima en la industria maquiladora.** 151(8), 167–176.

ALVES, C. DA C., HOEPERS, E., CORAZZA, E. J., SANTOS, G. J. DOS CRISTOFOLINI, R.; CRUZ, A. C. DA. (2019). Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. **Revista Produção Online**, 19(3), 1001–1026. <https://doi.org/10.14488/1676-1901.v19i3.3539>.

ARAÚJO, H. M. DE, TORRES, C., COSTA, F., ROBERTO, P.; TAVARES, L. (2015). Análise de tendência nas séries de precipitação na região metropolitana do Cariri – Ceará. XV SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE ANÁLISE, **Anuais 2015**, 1–10.

CORTEZ, P. (2002), **Modelos inspirados na natureza para a previsão de séries temporais.** 186 f. Tese (Doutorado) - Curso de Informática, Universidade do Minho, Campus de Azurém, 2002. Disponível em:

<<https://repositorium.sdum.uminho.pt/bitstream/1822/13/1/cortez.pdf>>. Acesso em: 18 set. 2023.

HEIZER, J.; RENDER, B. (2001), **Administração de Operações: Bens e Serviços.** 5. ed. Rio de Janeiro.

LIMA, J. E. C., CASTRO, L. F. DE; CARTAXO, G. A. A. (2019). Aplicação do Modelo SARIMA na Previsão de Demanda no Setor Calçadista / Application of the SARIMA Model in the Forecast for Demand in the Footwear Sector. ID on Line **REVISTA DE PSICOLOGIA**, 13(46), 892–913. <https://doi.org/10.14295/idonline.v13i46.1875>.

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

MIELKE, L. V.; VILLAS BOAS, P. (2022). Uso de Modelos de Decomposição em Componentes Não Observáveis para predição de séries temporais não estacionárias de commodities agrícolas. II Workshop de Matemática, Estatística e Computação Aplicadas à Indústria.

MORETTIN, P. A.; TOLOI C. M. C. (2006), **Análise de Séries Temporais.** 2ª ed. São Paulo.

PELLEGRINI, F.R. **Metodologia para implementação de Sistemas de Previsão de Demanda.** Porto Alegre RS: UFRS, 2000. 146p. (Dissertação de Mestrado em Engenharia de Produção). Universidade Federal do Rio Grande do Sul. Rio Grande do Sul.

TUBINO, D. F., Manual de Planejamento e Controle da Produção. São Paulo: Atlas, 1997.