



## Analysis of energy accumulators demand using time series

### Análise da demanda de acumuladores de energia utilizando séries temporais

CAVALCANTE, Thiago Sales<sup>(1)</sup>; FEITOSA, Matheus<sup>(2)</sup>; RODRIGUEZ, Tulio Fidel Orrego<sup>(3)</sup>; GOMES, Susane de Farias<sup>(4)</sup>

<sup>(1)</sup> 0000-0003-2914-2064; UFPE CAA, Caruaru, Pernambuco (PE), Brasil. thiago.salecavalcante@ufpe.br.

<sup>(2)</sup> 0000-0001-5659-6235; UFPE CAA, Caruaru, Pernambuco (PE), Brasil. matheus.feitosa@ufpe.br.

<sup>(3)</sup> 0000-0003-3414-1496; UFPE, Recife, Pernambuco (PE), Brasil. tuliofor@gmail.com.

<sup>(4)</sup> 0000-0001-9177-2046; UFAL, Penedo, Alagoas (AL), Brasil. susane.gomes@penedo.ufal.br.

#### ABSTRACT

The use of statistical methods for forecasting demand helps managers in decision making, especially when it is necessary to carry out production planning. Therefore, it is extremely important to know the demand for a particular product, especially when it comes to lines of jobbing production systems in which transforming resources are shared between products. Following this idea, the manufacturing time of the products plays a relevant role both for the production programming to avoid incurring higher costs incurred in storage, obsolescence, among others. In order to overcome these difficulties by providing information on future sales of the product to the decision maker, this work uses time series of demand that were provided by the manufacturer of energy accumulators to forecast the demand for batteries. The study was aided by forecasting methods. Among these methods, the autoregressive integrated time series method – ARIMA – stands out, which was used and evaluated the accuracy of its forecasts. However, it was found that the additive Holt-Winters method presented the best fit for the data of this research. With the application of this methodology, it is expected to contribute to the efficiency of the programming of manufacturing processes.

#### RESUMO

O uso de métodos estatísticos para a previsão da demanda auxilia gestores na tomada de decisão, principalmente, quando é preciso realizar o planejamento da produção. Portanto, é de suma importância conhecer a demanda de determinado produto, especialmente, quando se trata de linhas de sistemas de produção do tipo *jobbing* no qual os recursos transformadores são compartilhados entre os produtos. Seguindo esta ideia, o tempo de fabricação dos produtos toma um papel relevante tanto para a programação da produção para se evitar incorrer em maiores custos despendidos da armazenagem, obsolescência, entre outros. Visando atingir essas dificuldades ao fornecer informações de vendas futuras do produto ao tomador de decisão, este trabalho utiliza séries temporais da demanda que foram fornecidas pela empresa fabricante de acumuladores de energia para a previsão da demanda de baterias. O estudo foi auxiliado por métodos de previsão. Entre esses métodos, destacam-se o método autorregressivo integrado de séries temporais – ARIMA – que foi utilizado e avaliada a precisão das suas previsões. Contudo, foi encontrado que o método de Holt-Winters aditivo apresentou o melhor ajuste para os dados desta pesquisa. Espera-se com a aplicação desta metodologia contribuir para a eficiência da programação dos processos de manufatura.

#### INFORMAÇÕES DO ARTIGO

##### Histórico do Artigo:

Submetido: 10/06/2022

Aprovado: 07/10/2022

Publicação: 10/10/2022



**Palavras-chaves representativas do trabalho, estas não devem estar contidas no título do artigo.**

##### Keywords:

Demand forecasting, forecasting methods, temporal series, energy accumulators.

##### Palavras-Chave:

Previsão da demanda, métodos de previsão, séries temporais, acumuladores de energia.

## **Introdução**

A previsão de demanda é uma das atividades de gestão mais importantes para a tomada de decisões gerenciais, pois o sucesso futuro de qualquer empresa depende em grande parte de como o gestor tem a experiência necessária para descobrir e entender tendências e formular estratégias adequadas para absorver essas demandas. Nesse contexto, o planejamento com viés estratégico e o direcionamento de uma empresa dependem da correta identificação e previsão de novas mudanças no ambiente de negócios.

O estudo da previsão da demanda tem como objetivo fornecer informações sobre as necessidades futuras de materiais da empresa, assim, a produção pode ser planejada com antecedência, com os recursos produtivos disponíveis na quantidade, momento e de qualidade satisfatória (Queiroz & Cavalheiro 2003). Portanto, essa previsão é a base para o planejamento estratégico da produção e fundamental para o bom funcionamento de uma organização (Tubino, 1997).

Por meio deste estudo ainda, os recursos podem ser planejados, alocados e expandidos para reduzir custos desnecessários causados por decisões erradas. Entretanto, com frequência, a produção não consegue responder rapidamente a aumentos bruscos da demanda, havendo necessidade de haver estoques de produtos acabados para atender a esses aumentos; em outras ocasiões, a entrega de matérias-primas não acompanha as necessidades da produção, pelo que também se justificam os seus estoques (Moreira 2011).

O estoque dentro de uma empresa pode se tornar uma estratégia competitiva, já que os clientes querem os produtos após a efetuação da compra. Muitas empresas não sabem a quantidade de produtos que deve estar estocado para atender a demanda, gerando acúmulo ou falta de estoque dentro da empresa.

Por meio de um sistema de previsão de demanda eficaz, seria possível ter uma redução no custo logístico e uma otimização dos estoques na empresa. Isto é, um modelo que nos forneça uma análise do volume total que será demandado pelos clientes, se tornando, então, uma ferramenta de extrema importância para toda a organização.

Com esta dificuldade descrita anteriormente, os métodos estatísticos veem como uma das soluções para o problema de gerenciamento de estoque para sempre estar aptos a responder à demanda. As empresas costumam usar esses métodos estatísticos em diferentes campos da produção, como gerenciamento de estoque, planejamento de produção, programação de recursos humanos, controle de processo, etc. O

principal objetivo da utilização desses métodos é prever eventos futuros a fim de reduzir o risco de tomada de decisão (Veríssimo et al., 2012).

Também, a utilização da previsão através de series temporais fornece informações para a tomada de decisão em diversas áreas, por exemplo, a legislativa no caso de venda de álcool vs futebol, proposta por Nepomuceno et al. (2017) e que forneceu a sustentação científica para a reconsideração à proibição de venda de álcool nos estádios do estado de Pernambuco-Brasil; na área da saúde, a análise de séries temporais toma um papel muito importante em estudos como o sugerido por Earnest et al. (2005), para prever e monitorar o número de camas ocupadas durante o surto de SARS em Singapura e, o proposto por Nepomuceno et al. (2022), cujo estudo visa avaliar o impacto na mobilidade quando a sociedade foi cercada pela pandemia do COVID 19 através dos relatórios de mobilidade comunitária.

Visando a relevância na utilização das séries temporais e métodos de previsão como ferramenta para a obtenção de informações que apoiem a tomada de decisão, o presente trabalho visa realizar a previsão da demanda de acumuladores de energia (bateria) sustentado com os dados históricos da demanda deste produto. A bateria é um produto caracterizado por um extenso tempo de produção, demandando um grande número de materiais para sua construção, assim como, a utilização de máquinas para a transformação do material. Portanto, apoiar o planejamento da cadeia de suprimentos da organização é o principal objetivo deste estudo.

O uso de métodos estatísticos para a previsão favorece à tomada de decisão influenciando o dimensionamento de estoque e respeitando o prazo de validade do produto para períodos de três meses. Desta forma, espera-se garantir o atendimento ao cliente de forma eficaz, manter o produto pelo menor tempo possível no estoque garantindo não incorrer em custos extras pelo armazenamento, diminuir o número de setups na fábrica e a ótima rotatividade dos produtos.

## **Referencial teórico**

A previsão é basicamente a estimativa e análise de eventos futuros de uma temática específica ou demanda por um produto ou serviço; a utilização de diferentes técnicas para encontrar relações entre os dados históricos, estimativas de marketing, informações promocionais e outros insumos no caso de prever a demanda é o componente da previsão. Desta forma, a produção pode ser planejada com maior efetividade, garantindo os recursos transformadores e transformados na quantidade, momento e de qualidade desejada (Queiroz & Cavalheiro 2003). A base da maioria das decisões de

negócios orientadas para o futuro é estabelecida por meio da previsão de demanda, portanto, é uma ferramenta importante para decisões de gerenciamento e de planejamento estratégico.

Em termos de tomada de decisão no dia a dia de uma organização, o processo de estabelecimento de previsões é uma das ações mais importantes. Por exemplo, no setor industrial, medir a qualidade preditiva é essencial para reduzir significativamente a variabilidade do processo de produção, pois os produtos devem ser fabricados dentro do escopo de medidas de conformidade (Souza et al., 2008; Veríssimo et al., 2012).

Portanto, a previsão da demanda é a base para o planejamento estratégico da produção e fundamental para o bom funcionamento de uma organização (Tubino, 1997).

### ***Métodos estatísticos de previsão por séries temporais***

Os métodos estatísticos de previsão de séries temporais baseiam-se na ideia de que observações anteriores contêm informações sobre seus padrões de comportamento futuros. A essência desses métodos é identificar o padrão da sequência, separá-lo do ruído contido nas observações individuais e usá-lo para prever o valor futuro da sequência (Henning et al., 2010; da Silva & Costa 2016).

O objetivo da análise de série temporal é desenvolver modelos (estatísticas e/ou matemáticas) que descrevem completamente o processo de geração de dados para prever o comportamento futuro das variáveis dentro de um determinado período de planejamento.

Ao longo dos anos um grande número de métodos estatísticos tem sido desenvolvido para analisar as séries temporais, mas cada método tem suas próprias forças e limitações. Visando obter resultados que representem a série temporal analisada, é preciso interagir com um grande número destes métodos.

Portanto, a metodologia mais abordada para a análise de séries temporais de acordo com Ragsdale (2009) envolve testar várias técnicas de modelagem no mesmo conjunto de dados e avaliar o seu desempenho em relação ao grau de precisão da previsão, e assim, conhecer como essas técnicas auxiliam na explicação do comportamento das variáveis.

Contudo, é preciso a avaliação do desempenho de cada um dos modelos com o auxílio de critérios para seleção. Modelos de verossimilhança, como o Critério de Informação de Akaike (AIC), possui maior ênfase, seguido pelo teste da Razão de Verossimilhança (TRV) e o Critério Bayesiano de Schwarz (BIC).

Um desses modelos foi proposto por Box-Jenkins denominado de ARIMA – modelos Autorregressivos Integrados de Médias Móveis e, cuja metodologia, baseia-se em analisar o comportamento da correlação seriada ou autocorrelação dos valores da série temporal para com isto realizar previsões (Bandura et al., 2019).

## **Procedimentos metodológicos**

### ***Dados***

Os dados em questão são referentes a acumuladores de energia. Estes produtos fazem parte do portfólio da empresa e possuem uma complexidade na produção, tendo em vista ser um processo tecnológico novo, que ainda não possui uma demanda constante que justifique a ampliação da produção. A ideia da análise tem por objetivo o planejamento de demanda desse produto, tendo como solução a construção de um estoque que, respeitando o prazo de validade do produto, consiga um período de vendas trimestral, melhorando assim o número de setups desse modelo em fábrica e garantindo o atendimento ao cliente de forma satisfatória.

Na série de dados adotada para esse trabalho percebe-se facilmente a presença de picos e uma certa sazonalidade aparente entre 7-9 semanas. Além disso, a série em questão tem características de estacionariedade, e os dados estão disponibilizados em um banco de dados que mostram as demandas semanais do produto por um período de 2 anos (2018 e 2019).

Foram excluídas do banco de dados algumas semanas que possuíam demanda zerada, tendo em vista conversas com os gestores que explicaram não ser um comportamento frequente para esse produto.

### ***Procedimentos***

Com o objetivo de realizar a previsão da demanda do produto analisado, com base nos dados, testou-se a utilização dos métodos de Suavização Exponencial e o processo autorregressivo integrado de médias móveis - *ARIMA*. Em seguida, realizou-se uma análise visual dos dados plotados procurando identificar qual dos métodos disponíveis, melhor se ajusta ao conjunto de dados. Notou-se que os gráficos apresentavam

uma possível sazonalidade ou tendência. Apesar disto, optou-se por testar todos os métodos de suavização estudando os dados, bem como o modelo ARIMA e decidir qual deles seria o melhor com base nos erros apresentados.

Para aplicação do ARIMA, em um primeiro momento, realizou-se o teste de Estabilidade, para checar se a percepção dos dados estava correta. O resultado do teste retornou que os dados seriam estacionários, isso quer dizer que eles não possuíam nem sazonalidade ou tendência. Procurou-se, portanto, um modelo que melhor se adequa aos dados.

Em seguida, rodou-se a Função de Autocorreção (ACF) e Função de Autocorreção Parcial (PACF), em que se notou que os dados apresentaram comportamento de um modelo de ruído branco. Com isso estabelecido, passou-se então a testar-se diversos modelos ARIMA diferentes buscando encontrar o que melhor se ajusta aos dados e, uma vez que isso aconteça, realiza-se as previsões. Em seguida, decidiu-se utilizar a função *auto.arima* no software R<sup>®</sup> para verificar se o modelo escolhido apresenta o melhor desempenho.

Na próxima etapa, foram gerados os modelos de suavização exponencial com os dados, optou-se que os valores dos coeficientes de suavização (alfas, betas, gamas) e de amortecimento (fis) seriam determinados pelo software R<sup>®</sup> de forma iterativa, já que o mesmo já iria decidir os melhores resultados possíveis. Em relação ao valor do período de sazonalidade, testamos 4 valores diferentes com base na análise visual dos gráficos, escolhendo aquele que apresentou o menor erro.

Por fim, foram comparados os indicadores de desempenho: MAPE (Erro Percentual Absoluto Médio) e RSME (Raiz Quadrada De Desvio Médio) para os modelos previstos.

## **Resultados e discussões**

De maneira geral, o conjunto de dados possui alguns *outliers* que não foram retirados, tendo em vista que a presença desses representavam alguns picos de venda, o que está alinhado ao propósito do trabalho (Figura 1.a).

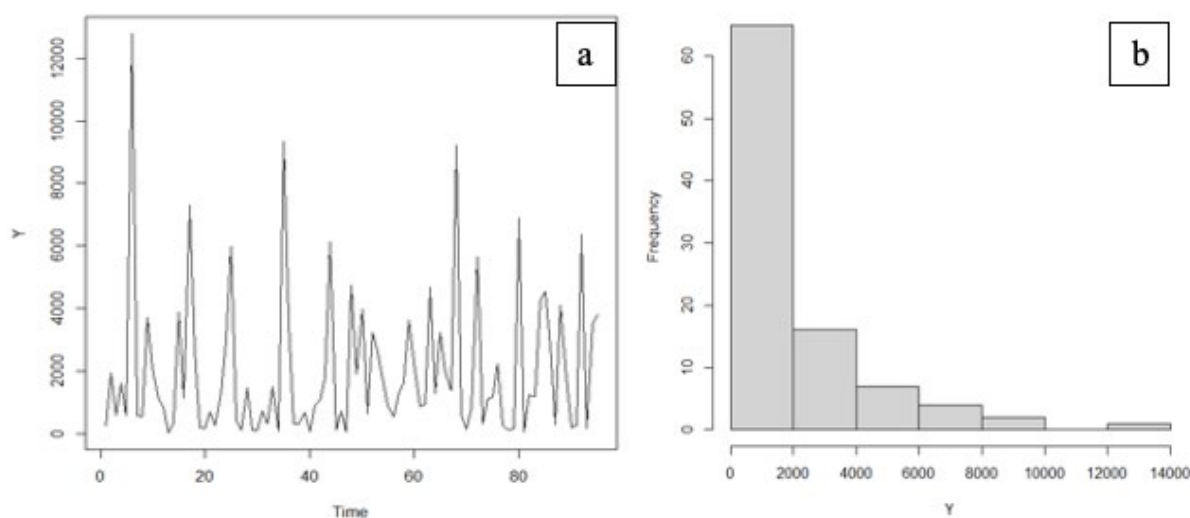
Pedidos que variam de 12 até 12000 unidades são identificados na base de dados fornecida pela empresa envolvida no estudo. Também, foi observado que o grupo de pedidos contendo até 4 mil unidades representa aproximadamente 80% das observa-

ções. Portanto, a média da amostra se encontra inerentemente nesse grupo. Esta e outras informações relevantes para a caracterização da amostra são apresentadas na Tabela 1.

O restante das observações contidas na amostra, representa pedidos isolados que contém grandes número de unidades solicitadas pelos clientes (Figura 1.b)

**Figura 1.**

a) Observações da amostra vs Tempo. b) Histograma



**Tabela 1.**

*Estatística descritiva do conjunto de dados*

<i>Min.</i>	<i>1st Qu.</i>	<i>Median</i>	<b><i>Mean</i></b>	<i>3rd Qu.</i>	<i>Max.</i>	<i>&gt;sd(Y)</i>
<b>12</b>	306	1140	<b>2001</b>	2892	12807	2.357.359

Inicialmente, procede-se a fornecer o set de dados ao software R<sup>®</sup> que contém a biblioteca do teste *Dickey-Fuller*, em seguida, determina-se se os dados utilizados nesta pesquisa podem ser declarados “estacionários”.

A Figura 2 apresenta as principais informações após os cálculos do teste, concluindo que a série temporal sob análise possui características como: não possui tendência, exibe variância constante ao longo do tempo e tem uma estrutura de autocorrelação constante ao longo do tempo, portanto, pode-se concluir que a série temporal é “estacionária”. O set de dados ao ser estacionário significa que é necessário adotar um modelo novo.

**Figura 2.**  
*Teste Dickey-Fuller*

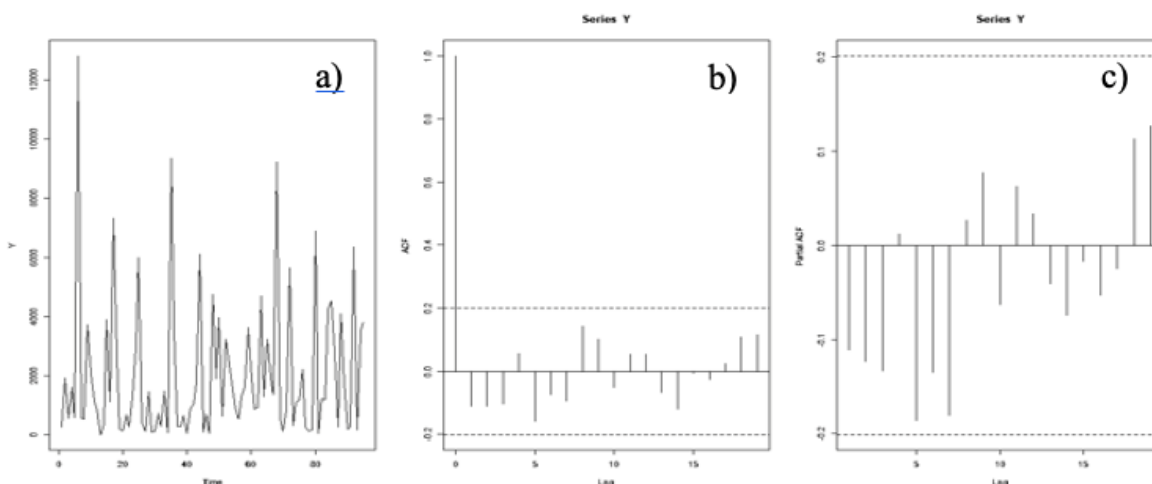
```
> adf.test(Y)

Augmented Dickey-Fuller Test

data: Y
Dickey-Fuller = -5.7024, Lag order = 4, p-value = 0.01
alternative hypothesis: stationary
```

Decidiu-se então por realizar os testes da Função de Autocorreção (ACF) e Função de Autocorreção Parcial (PACF), procurando aprofundar a análise feita nos dados e descobrir a ordem do polinômio que seria utilizado no modelo. A Figura 3 apresenta os dados da serie temporal (a) e resultados dos testes ACF (b) e PACF (c), os quais se presume seguem um modelo de ruído branco, ou seja, um processo puramente aleatório impossibilitando o fornecimento de informações relacionadas a ordem.

**Figura 3.**  
*a) Demanda b) ACF c) PACF*



Em seguida, procede-se com a estimação dos parâmetros do modelo autorregressivo integrado de médias móveis – ARIMA com a realização do teste utilizando o método de busca exaustiva ou variação ordenada dos parâmetros com o intuito de estimar os parâmetros deste. Os resultados das tentativas são avaliados em busca de selecionar o menor valor do *critério de informação do Akaike* (AIC); representando o modelo como indicado nos instrutivos pelo próprio autor e que representa a idoneidade do modelo para a solução.

A Figura 4 apresenta os valores dos parâmetros de entrada contidos na forma de series numeradas ( $m1 - m6$ ) e, no que cada serie contém no formato de linhas uma



combinação dos parâmetros característicos do processo ( $p, d, q$ ). Além disso, o resultado da análise o critério do Akaike (AIC=aic) são fixados na parte inferior do grupo de séries.

Assim, o menor valor de *aic* (744,985) é fornecido pelo modelo representado pela sigla *m1*, configurado como “*arima(Y, order=c(1,0,1))*”; esta configuração é então selecionado para dar continuidade com o estudo e, posteriormente, a execução da previsão da demanda.

**Figura 4.**

*Modelos ARIMA e seus respectivos AIC*

```

m1 <- arima(Y,order=c(1,0,1))
m2 <- arima(Y,order=c(1,0,2))
m3 <- arima(Y,order=c(1,0,3))
m4 <- arima(Y,order=c(1,0,4))
m5 <- arima(Y,order=c(1,0,5))
m6 <- arima(Y,order=c(1,0,6))

```

	m1.aic	m2.aic	m3.aic	m4.aic	m5.aic	m6.aic
1	1744.985	1746.76	1748.662	1750.953	1750.194	1752.194

```

m1 <- arima(Y,order=c(2,0,1))
m2 <- arima(Y,order=c(2,0,2))
m3 <- arima(Y,order=c(2,0,3))
m4 <- arima(Y,order=c(2,0,4))
m5 <- arima(Y,order=c(2,0,5))
m6 <- arima(Y,order=c(2,0,6))

```

	m1.aic	m2.aic	m3.aic	m4.aic	m5.aic	m6.aic
1	1746.734	1748.096	1749.5	1751.232	1752.058	1753.913

```

m1 <- arima(Y,order=c(3,0,1))
m2 <- arima(Y,order=c(3,0,2))
m3 <- arima(Y,order=c(3,0,3))
m4 <- arima(Y,order=c(3,0,4))
m5 <- arima(Y,order=c(3,0,5))
m6 <- arima(Y,order=c(3,0,6))

```

	m1.aic	m2.aic	m3.aic	m4.aic	m5.aic	m6.aic
1	1748.639	1749.796	1746.558	1748.008	1750.958	1753.913

Após a escolha do modelo do tipo ARIMA (*m1*), continua-se a utilizar a função “*auto.arima*” do softwatr *R*<sup>®</sup> para efetuar a validação deste modelo e, obter assim, o melhor ajuste do modelo. Os resultados da função “*auto.arima*” (Figura 5) evidencia os seus atributos e, conclui que o modelo escolhido era de fato o mais ajustado as condições.

**Figura 5.**

*Modelo ajustado ARIMA*

```

> auto.arima(Y)
Series: Y
ARIMA(1,0,1) with non-zero mean

Coefficients:
      ar1      ma1      mean
 0.6564 -0.8694 1973.5665
s.e. 0.1525 0.1026 95.2346

sigma^2 estimated as 5258139: log likelihood=-868.49
AIC=1744.98 AICC=1745.43 BIC=1755.2

```

Nesta etapa, avaliar o modelo previamente selecionado com a amostra teste com o intuito de conhecer seu rendimento. A Figura 6 apresenta o sumário da etapa de treinamento do modelo ARIMA, contendo os coeficientes de acurácia, o erro quadrático médio (RMSE), erro médio absoluto (MAE) e o erro percentual médio (MAPE).

**Figura 6.**

*Sumário do modelo ARIMA utilizado*

```
> summary(m1)

Call:
arima(x = Y, order = c(1, 0, 1))

Coefficients:
      ar1      ma1  intercept
 0.6564 -0.8694 1973.5665
s.e. 0.1525 0.1026 95.2346

sigma^2 estimated as 5092093:  log likelihood = -868.49,  aic = 1744.98

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set 11.15617 2256.567 1693.302 -547.891 582.2013 0.720402 0.02803643
```

O modelo ajustado é utilizado para obter uma serie de previsões da demanda (Figura 7) com o intuito de visualizar os dados obtidos e, posteriormente, realizar a análise dos resíduos.

**Figura 7.**

*Previsão da demanda do produto para 6 meses*

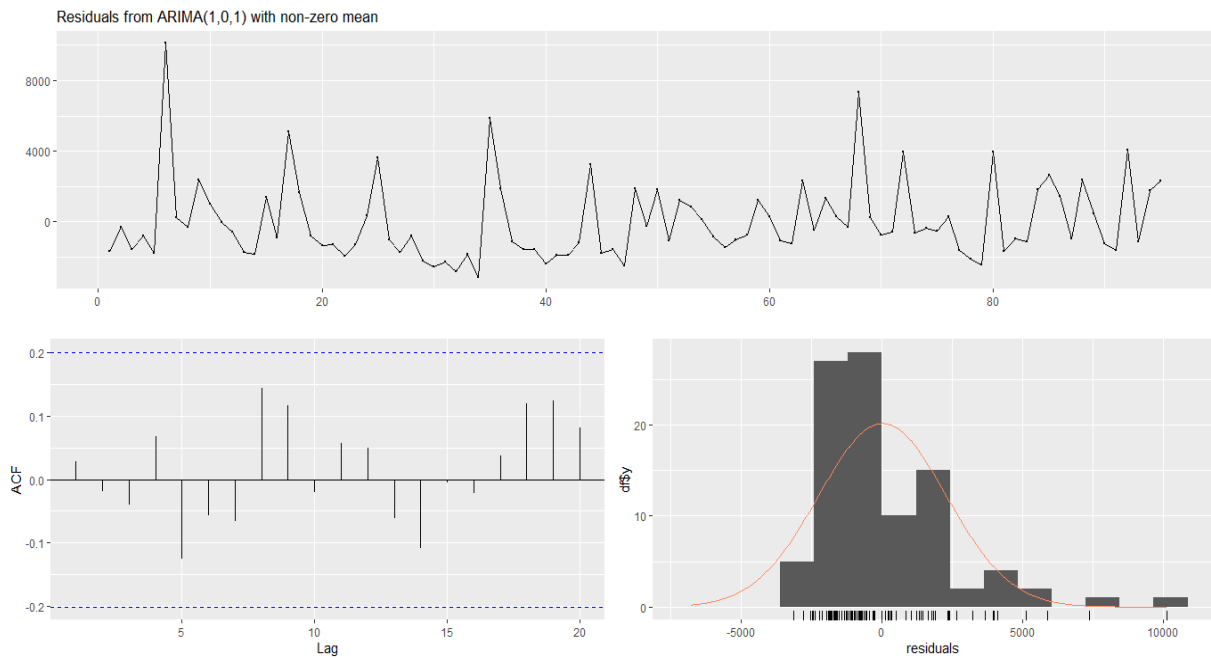
```
> pred2
$pred
Time Series:
Start = 96
End = 119
Frequency = 1
 [1] 1139.979 1426.418 1614.431 1737.838 1818.840 1872.007 1906.905 1929.812
 [9] 1944.847 1954.716 1961.193 1965.445 1968.236 1970.067 1971.270 1972.059
[17] 1972.577 1972.917 1973.140 1973.287 1973.383 1973.446 1973.487 1973.515

$se
Time Series:
Start = 96
End = 119
Frequency = 1
 [1] 2256.567 2307.212 2328.692 2337.885 2341.835 2343.535 2344.267 2344.582
 [9] 2344.718 2344.776 2344.801 2344.812 2344.817 2344.819 2344.820 2344.820
[17] 2344.820 2344.820 2344.820 2344.820 2344.820 2344.820 2344.820 2344.820
```

Na Figura 8 são apresentados os gráficos relacionados aos resíduos gerados pelos modelos. Observa-se que os resíduos parecem seguir uma distribuição normal, mas possuem *outliers*, bem como não apresentaram aparentemente um desvio padrão constante. Já na Figura 9, percebe-se que os resíduos dos dados se aproximam à reta normal, mas talvez fosse possível encontrar um modelo que melhor se encaixa.

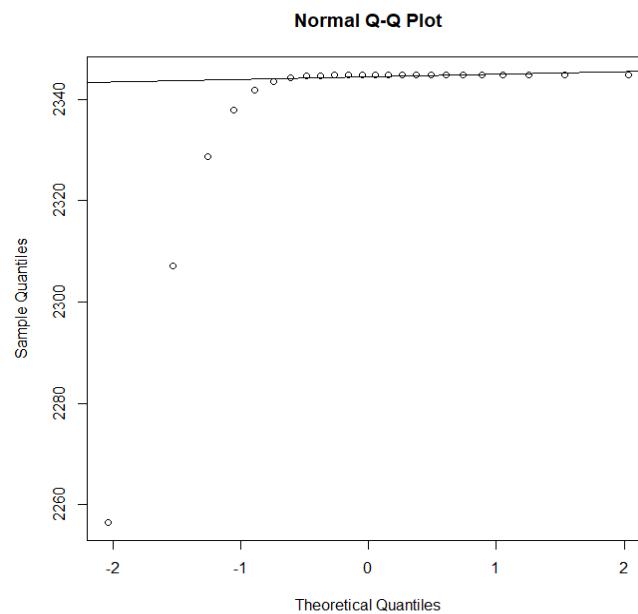
**Figura 8.**

*Dados relacionados aos resíduos do modelo*



**Figura 9.**

*Plot dos resíduos gerados e a curva normal*



Após observações feitas anteriormente, foi realizado o teste de *Ljung-Box* para saber se o modelo adotado realmente se ajusta. Contudo, ao contemplar o resultado do teste, resultou-se que a hipótese nula foi reprovada, o que significa que o modelo não é o indicado para representar os dados (Figura 10).

**Figura 10.***Teste Ljung-Boxl*

```
> Box.test(pred2$se, type = "Ljung-Box")
```

```
Box-Ljung test
```

```
data: pred2$se
```

```
X-squared = 4.8255, df = 1, p-value = 0.02804
```

Em seguida, testes de Suavização exponencial foram realizados, sendo mostrados na Figura 11 os sumários de cada método, nos quais contém os valores dos coeficientes de suavização e de amortecimento (fis) adotados pelo software R®.

**Figura 11.***Sumário dos métodos de suavização exponencial*

Método	Parâmetros de suavização					Parâmetros iniciais						
	Alpha	Beta	Phi	Gama	ma	l	b	s	Sigma	AIC	AICc	BIC
Suavização exponencial	1e-04	-	-	-		2000.962	-	-	2370.117	1913.029	1913.293	1920.691
Holt's	1e-04	1e-04	-	-		1353.789	10.350	-	2402.486	1917.541	1918.215	1930.310
Damped Holt's	1e-04	1e-04	0.8	-		1333.011	228.561	-	2419.645	1919.844	1920.798	1935.167
Aditivo	0.0032	0.0032	-	1e-04		2259.537	-12.985	547.34	2416.456	1925.902	1930.395	1959.101
Multiplicativo	0.0064	0.0064	-	1e-04		2793.135	-31.585	1.3841	1.5422	1956.945	1961.439	1990.145

Em seguida, considerou-se a avaliação de acurácia dos modelos através do erro percentual médio (MAPE) e erro quadrático médio (RMSE). A Tabela 2 sumariza os valores para os fatores de avaliação de acurácia dos modelos. Pode-se observar que o modelo *Suavização Exponencial de Holt-Winters Aditivo* é o que se aproxima mais à realidade dos dados amostrais, apresentando o menor valor do erro percentual médio.


**Tabela 2.***Estatísticas descritivas básicas do conjunto de dados*

	Método	MAPE	RMSE
1	ARMA	582,2013	2256,567
2	Suavização Exponencial Simples	595,171	2345,036
3	Suavização Exponencial de Holt (s/ amort.)	528,5568	2351,363
4	Suavização Exponencial de Holt (c/ amort.)	661,6457	2355,114
5	Suavização Exponencial de Holt- Winters - aditivo	425,7512	2258,687
6	Suavização Exponencial de Holt- Winters - multiplicativo	476,4196	2277,239

Com a seleção do modelo de previsão de demanda mais ajustado entre os avaliados neste estudo, procede-se a sua utilização com o objetivo de obter uma série de previsões. A Figura 12 apresenta a série temporal e a parcela de 6 meses que foram previstos utilizando o modelo de *suavização exponencial de Holt-Winter aditivo*.

**Figura 12.**

*Previsão da demanda para o produto nos próximos 6 meses*



### **Considerações Finais**

Por fim, podemos perceber que o modelo ARIMA é certamente dependente da qualidade do ajuste de dados. Assim, nesta pesquisa temos que o melhor método aplicado foi o de Holt-Winters aditivo, pois foi o que melhor representou o comportamento da base de dados, respeitando a sazonalidade e apresentando o menor MAPE e RSME. Porém o modelo apresenta limitações. Referente ao alto erro da previsão, temos dois fatores principais de impacto: i) a quantidade de dados utilizados foi insuficiente para que os modelos pudessem ser utilizados da melhor forma e ii) a base de dados apresenta apenas o histórico de venda do produto.

Para se aprimorar o modelo seria necessário o acréscimo de novas variáveis de mercado que possuíssem o poder de representação dessa demanda de forma mais satisfatória. Também, é importante ressaltar que há outras ferramentas como redes neurais que conseguem envolver grande número de variáveis para realizar previsões.

### **Agência financiadora**

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio na construção deste trabalho.

## Referências

- Bandura, E., Bueno, J. C. M., Jadoski, G. S., & Junior, G. F. R. Aplicações do modelo ARIMA para estatística na análise de dados em série temporal. *Pesquisa Aplicada & Agrotecnologia*, Guarapuava-PR, v.12, n.3, p.145-150, Set-Dez., 2019. DOI: 10.5935/PAeT.V12.N3.15.
- da Silva, D. A., & Costa, D. F. (2016). A utilização do modelo Holt Winters na elaboração de um orçamento de resultado de uma cooperativa de crédito rural. *Anais Do Congresso Brasileiro De Custos - ABC*. Recuperado de <https://anaiscbc.emnuvens.com.br/anais/article/view/774>
- Earnest, A., Chen MI, Ng. D., & Sin, L. Y. (2005). Using autoregressive integrated moving average (ARIMA) models to predict and monitor the number of beds occupied during a SARS outbreak in a tertiary hospital in Singapore. *BMC Health Services Research*, 5(1), 36.
- Henning, E., Alves, C. C., & Konrath, A. C. (2010). Previsão de vendas de rodízios para móveis em uma empresa de médio porte. In: ICPR AMERICAS - 5th Americas International Conference on Production Research, Bogotá, Colômbia. Proceedings... Bogotá: 2010.
- Moreira, D. A. (2011). *Administração da Produção e Operações*. (2ª ed.). Cengage Learning.
- Nepomuceno, T. C. C., de Moura, J. A. & Silva, L. C., Costa, A. P. C. S. (2017). Alcohol and violent behavior among football spectators: An empirical assessment of Brazilian's criminalization. *International Journal of law, crime and justice* (51), 34-44.
- Nepomuceno, T. C. C., Garcez, T. V, Silva, L. C., & Coutinho, A. P. (2022). Measuring the mobility impact on the COVID-19 pandemic. *Mathematical Biosciences and Engineering*, 19(7), 7032-7054. doi: 10.3934/mbe.2022332
- Queiroz, A. A. & Cavalheiro, D. (2003, 21 a 24 de outubro). *Método de previsão de demanda e detecção de sazonalidade para o planejamento da produção de indústrias de alimentos* [conferência]. XXIII Encontro Nac. de Eng. de Produção - Ouro Preto, MG, Brasil, pp. 1-8.
- Rasgdale, C. T. (2009). *Modelagem e Análise de Decisão*. Cengage Learning.
- Souza, G.P., Samohyl, R.W., & Miranda, R. G. (2008). *Métodos Simplificados de Previsão Empresarial*. Editora Ciência Moderna.
- Tubino, D. F. (1997). *Manual de Planejamento e Controle de Produção*. Atlas.
- Veríssimo, A., Alves, C. C., Henning, E., Do Amaral, C. E., & Da Cruz, A. C. (2012). Métodos estatísticos de suavização exponencial holt-winters para previsão de demanda em uma empresa do setor metal mecânico. *Revista gestão industrial*, 8(4).

## Apêndice A - Rotinas do R

```
# Abaixo se encontram as livrarias contendo as funções usadas
library(readxl)
library(arfima)
```

```

library(forecast)
library(tseries)
library(MuMIn)

#Recebimento dos dados da tabela
Dados <- read_excel("C:/Users/mathe/Downloads/DEMANDA POR SEMANA (1).xlsx",
  sheet = "BANCO DE DADOS TRATADO")
#Escolha da coluna em relação a variável escolhida
Y <- Dados$`DEMANDA - PRODUTO 2`
#Plote dos dados utilizados
ts.plot(Y)
#Sumário e desvio padrão dos dados da variável
summary(Y)
sd(Y)
#Plote dos gráficos Boxplot e Historiograma
boxplot(Y)

hist(Y)

#Realização do teste de Dickey-Fuller para confirmar estacionaridade
adf.test(Y)

#Plote dos três gráficos que mostram o comportamento da variável Y
par(mfrow = c(1, 3))
ts.plot(Y)
acf(Y)
pacf(Y)

#Criação de modelos ARIMA
m1 <- arima(Y,order=c(1,0,1))
m2 <- arima(Y,order=c(1,0,2))
m3 <- arima(Y,order=c(1,0,3))
m4 <- arima(Y,order=c(1,0,4))
m5 <- arima(Y,order=c(1,0,5))
m6 <- arima(Y,order=c(1,0,6))

#Geração dos dados AIC dos modelos criados e sua visualização
IC <- data.frame(m1$aic, m2$aic, m3$aic, m4$aic, m5$aic, m6$aic)
View(IC)

#Confirmação do de que o melhor modelo foi escolhido e a apresentação dos seus dados
auto.arima(Y)
summary(m1)

#Previsão da demanda com base no modelo escolhido para 6 meses a frente
pred1 <- predict(m1, n.ahead = 24)
pred1

#Gerar resíduos do modelo
checkresiduals(m1)

#Plote dos dados em relação a normalização
par(mfrow = c(1, 1))
qqnorm(pred1$se)
qqline(pred1$se)

#Teste para mostrar se o modelo é o melhor possível
Box.test(pred1$se, type = "Ljung-Box")

#Realiza-se a Suavização Exponencial Simples para 6 meses, plotando seu gráfico e gerando seu sumário
previsao <- ses(Y, h = 24)

```

```
plot(previsao)
```

```
summary(previsao)
```

```
#Realiza-se a Suavização Exponencial de Holt para 6 meses, plotando seu gráfico e gerando seu sumário
```

```
previsao <- holt(Y, h = 24)
```

```
plot(previsao)
```

```
summary(previsao)
```

```
#Realiza-se a Suavização Exponencial de Holt com amortecimento para 6 meses, plotando seu gráfico e gerando seu sumário
```

```
previsao <- holt(Y, damped = TRUE, h = 24)
```

```
plot(previsao)
```

```
summary(previsao)
```

```
#Mostrando que a variável Y tem sazonalidade de 8 semanas
```

```
y <- ts(Y, frequency = 8)
```

```
#Realiza-se a Suavização Exponencial Holt-Winters aditivo para 6 meses, plotando seu gráfico e gerando seu sumário
```

```
previsao <- hw(y, h= 24, seasonal = c("additive"))
```

```
plot(previsao)
```

```
summary(previsao)
```

```
#Mostrando que a variável Y tem sazonalidade de 8 semanas
```

```
y <- ts(Y, frequency = 8)
```

```
#Realiza-se a Suavização Exponencial Holt-Winters multiplicativo para 6 meses, plotando seu gráfico e gerando seu sumário
```

```
previsao <- hw(y, h= 24, seasonal = c("multiplicative"))
```

```
plot(previsao)
```

```
summary(previsao)
```



## Apêndice B - Dados utilizados

ANO	SEMANA	DEMANDA - PRODUTO 2
2018	1	264
2018	2	1932
2018	3	576
2018	4	1620
2018	5	589
2018	6	12807
2018	7	577
2018	8	540
2018	9	3720
2018	10	2076
2018	11	1140
2018	12	852
2018	13	12
2018	14	336
2018	15	3888
2018	16	1128
2018	17	7320
2018	20	2676
2018	21	204
2018	22	156
2018	23	696
2018	24	264
2018	25	1296
2018	26	2976
2018	27	5988
2018	28	432
2018	29	120
2018	31	1464
2018	32	96
2018	33	120
2018	34	732
2018	35	300
2018	36	1488
2018	37	84
2018	38	9348
2018	39	3588
2018	40	300
2018	41	300
2018	42	672
2018	43	60
2018	44	900
2018	45	1044
2018	47	1800
2018	48	6120
2018	49	96
2018	50	720
2018	51	48

ANO	SEMANA	DEMANDA - PRODUTO 2
2019	2	4752
2019	3	1896
2019	4	3960
2019	5	636
2019	6	3240
2019	7	2604
2019	8	1764
2019	9	900
2019	10	552
2019	11	1296
2019	12	1644
2019	13	3624
2019	14	2292
2019	15	876
2019	16	924
2019	17	4692
2019	18	1284
2019	19	3240
2019	20	1956
2019	21	1368
2019	22	9216
2019	23	576
2019	25	132
2019	26	828
2019	27	5640
2019	28	312
2019	29	1104
2019	30	1164
2019	31	2220
2019	32	264
2019	33	120
2019	34	168
2019	35	6888
2019	36	60
2019	37	1224
2019	38	1200
2019	39	4248
2019	40	4524
2019	42	2808
2019	43	276
2019	44	4080
2019	45	1776
2019	46	192
2019	47	264
2019	48	6348
2019	49	180
2019	50	3504
2019	51	3792