

# **Previsão de Demanda de Alimentos: estudo de caso na Marinha do Brasil**

**Luiz Sérgio Carvalho de Mello**  
**luiznvufrj@yahoo.com.br**  
**UERJ**

**Leonardo Fogaça Cardoso**  
**nardo.fogaca@gmail.com**  
**UERJ**

**José Francisco Moreira Pessanha**  
**professorjfm@hotmail.com**  
**UERJ**

**Resumo:** A Marinha do Brasil (MB) possui dentre as suas atividades administrativas a gestão contábil de alimentos, que demanda de seus gestores eficiência e eficácia na aplicação dos recursos públicos. Desta forma, o processo de previsão de demanda apresenta-se como uma opção de ferramenta gerencial para o planejamento e controle dos estoques de alimentos das Organizações Militares (OM). Com isto, esta pesquisa teve por objetivo avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para as atividades da gestão de estoques de alimentos das OM da MB. Como resultados, as previsões por meio dos métodos ARIMA e Holt-Winters apresentaram desvios relativos de 15,20% e 5,36%, respectivamente, em relação ao consumo acumulado anual de arroz em uma OM em 2019. O estudo avaliou que a utilização da previsão de demanda pode trazer benefícios gerenciais à gestão contábil de alimentos da Força no que tange às quantidades a serem inseridas na elaboração de processos licitatórios, bem como nas atividades de controle dos estoques.

**Palavras Chave:** Gestão de Alimentos - Previsão de Demanda - Marinha do Brasil - -

## 1. INTRODUÇÃO

A Administração Pública brasileira tem estabelecido cada vez mais critérios e mecanismos que busquem a precisão dos atos administrativos de seus órgãos, bem como alcancem a eficiência e eficácia na aplicação dos recursos públicos. Desta forma, cabe às instituições proverem seus gestores de ferramentas tecnológicas que contribuam com desenvolvimento adequado de suas tarefas em prol da excelência no serviço público (ALENCAR; FONSECA, 2016).

Recentemente, foi sancionada a Lei nº 14.133, de 01 de abril de 2021, que versa sobre às licitações e contratos. Esse dispositivo legal trouxe maior destaque para o princípio do planejamento nas aquisições públicas, ressaltando a importância da fundamentação das quantidades a serem contratadas com base em métodos quantitativos e no histórico de consumo dos itens (BRASIL, 2021).

Nesse contexto, a Marinha do Brasil (MB), como órgão da administração direta do governo federal, dispõe dentre as suas atividades administrativas, a gestão contábil de alimentos, que é responsável por adquirir, armazenar e controlar os estoques de gêneros alimentícios, além de fornecer diariamente as refeições aos militares que trabalham em navios e em Organizações Militares (OM) sediadas em terra (SCRIVANO; COSTA; COSTA, 2020).

Nesse escopo, com vistas ao aperfeiçoamento das práticas gerenciais na administração de estoque de alimentos, os métodos de previsão de demanda, operacionalizados por *softwares* estatísticos, apresentam-se como uma opção de ferramenta aos gestores, que podem vir a contribuir para o processo de planejamento e controle dos estoques (MELLO *et al.*, 2021).

Dentre os métodos estatísticos que viabilizam a obtenção de valores preditivos a partir de séries temporais, mencionam-se os métodos de Holt-Winters e ARIMA, ambos considerados clássicos por apresentarem bons resultados para estudos que buscam previsões mensais em diferentes tipos de organizações (MAKRIDAKIS; SPILIOTIS; ASSIMAKOPOULOS, 2018).

Com isso, este estudo busca responder ao seguinte problema de pesquisa: Como o processo de previsão de demanda pode contribuir para as atividades gerenciais da gestão de estoques de alimentos de Organizações Militares da Marinha do Brasil?

Como objetivo, a pesquisa busca avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para as atividades gerenciais da gestão de estoques de alimentos de Organizações Militares da Marinha do Brasil.

A relevância do estudo remete à possibilidade de contribuir para a mitigação de riscos de desperdício de alimentos e de recursos públicos, uma vez que, o processo de previsão de demanda pode trazer maior acurácia aos níveis de serviço prestado pelas OM da MB, no que tange aos aspectos da gestão contábil de alimentos.

Sem perda de generalidade, o estudo delimita-se a analisar o processo de previsão de demanda de um item de estoque de alimentos (arroz) de uma OM de ensino da Força para o ano de 2019, utilizando-se dos métodos ARIMA e Holt-Winters.

## 2. REFERENCIAL TEÓRICO

Esta seção abrangerá os conceitos teóricos que darão suporte ao trabalho na busca pelo cumprimento de seu objetivo de pesquisa.

## 2.1. GESTÃO CONTÁBIL DE ALIMENTOS NA MARINHA DO BRASIL

A Gestão Contábil de Alimentos da Marinha do Brasil possui seus regramentos dispostos na norma interna “SGM-305 – Normas sobre municiação”, que traz os preceitos a serem executados pelos gestores das OM no que tange às aquisições, armazenagem e controle dos estoques de gêneros alimentícios (BRASIL, 2015).

Para as escriturações das operações contábeis referentes ao setor de alimentação, a Força detém um sistema corporativo denominado Quaestor, que permite os lançamentos de entradas e saídas dos itens de estoque. Entretanto, esse sistema não possui funcionalidades que viabilizem a realização da previsão de consumo de um determinado gênero alimentício (MELLO *et al.*, 2021).

De acordo com Santana e Côrrea (2014), a Diretoria de Finanças da Marinha (DFM) é a Diretoria Especializada que exerce a função de setorial contábil junto à Secretaria do Tesouro Nacional (STN), além de emitir diretrizes às OM quanto aos aspectos contábeis do setor de alimentação, inclusive aqueles referentes à gestão dos estoques.

Adicionalmente, a DFM é responsável por gerenciar o sistema Quaestor, que é utilizado por navios e OM sediadas em terra que possuem a gestão contábil de alimentos. Em paralelo, o Sistema de Administração Financeira do Governo Federal (SIAFI) é utilizado nas aquisições dos itens de estoque. Nesse sentido, o Quaestor fornece informações gerenciais complementares, como relatórios que indicam a disponibilidade de cada gênero alimentício em estoque, bem como seu respectivo saldo contábil (BRASIL, 2015).

As saídas dos itens para o preparo das refeições também são registradas no sistema Quaestor, e seus valores contábeis representam o custo atrelado aos gêneros alimentícios (BRASIL, 2020). Desta forma, quando é realizada a projeção de consumo de item, poderá ser calculada paralelamente a projeção de custos que este representa (MACHADO; HOLANDA, 2010).

## 2.2. PREVISÃO DE DEMANDA DE ITENS DE ESTOQUE

Os processos de previsão de demanda são ferramentas essenciais à boa gestão de estoques nas organizações, haja vista que os itens armazenados correspondem a um montante de capital imobilizado (SAAVEDRA-NIEVES, 2018). Quando se trata de órgãos públicos, esses itens estocados correspondem à recursos públicos investidos em uma determinada atividade, sendo a instrumentalização da previsão de demanda uma oportunidade de melhoria na precisão das compras, bem como ao aperfeiçoamento das atividades logísticas do órgão (ALVES *et al.*, 2019).

Ballou (2006) menciona que o processo de previsão de demanda é um fator fundamental para o planejamento e controle dos estoques, uma vez que impacta nos setores de compras, controle dos itens armazenados e nas projeções de custos. Adicionalmente, Sousa *et al.* (2017) salientam que as estimativas de consumo efetuadas por meio de métodos estatísticos podem mitigar riscos de desperdício e deterioração de itens de estoque.

## 2.3. METODOLOGIA BOX & JENKINS (ARIMA)

A metodologia Box & Jenkins, também conhecida como modelo ARIMA (*Autoregressive Integrated Moving Average*), é uma abordagem largamente utilizada na previsão de séries temporais (CAMPOS; CORDEIRO, 2006). Barros *et al.* (2020) destacam que esse tipo de modelo pode ser decomposto em três componentes, quais sejam: Autorregressiva (AR); Integração (I) e de Médias Móveis (MA). Ainda de acordo com os

autores, a notação que representa este modelo é a ARIMA  $(p,d,q)$ , em que  $p$ ,  $d$  e  $q$  denotam a sua respectiva ordem. Neste caso,  $p$  e  $q$  são, respectivamente, os graus dos polinômios das partes autorregressiva e de média móvel da componente não sazonal, e  $d$  se traduz no número de diferenças simples para remover a tendência da série. A Equação 1 expressa de forma geral o modelo ARIMA  $(p,d,q)$ .

$$(1-\phi_1B-\dots-\theta_p\phi^p)(1-B)^d y_t=(1-\theta_1B-\dots-\theta_qB^q)\varepsilon_t \quad (1)$$

Na Equação 1,  $y_t$  denota a série temporal analisada e  $\varepsilon_t$  o erro aleatório (ruído branco) no mês  $t$ ,  $B$  expressa o operador de defasagem (por exemplo,  $B^L y_t = y_{t-L}$ ), enquanto  $\phi$  e  $\theta$  são, respectivamente, os coeficientes dos polinômios das partes autorregressiva (AR) e de média móvel (MA) do modelo que descreve o processo estocástico que governa a série temporal  $y_t$ .

Caso haja a presença de sazonalidade na série temporal, o modelo passa a ter a notação SARIMA (*Seasonal Autoregressive Integrated Moving Average*)  $(p,d,q) \times (P,D,Q)$  (MORETTIN; TOLOI, 2018), cuja expressão é apresentada na Equação 2:

$$(1-\phi_1B-\dots-\phi_pB^p)(1-\Phi_1B^S-\dots-\Phi_PB^{PS})(1-B)^d(1-B^S)^D y_t=(1-\theta_1B-\dots-\theta_qB^q)(1-\Theta_1B^S-\dots-\Theta_QB^{QS})\varepsilon_t \quad (2)$$

em que  $\Phi$  e  $\Theta$  são, respectivamente, os coeficientes das partes autorregressiva e de média móvel da componente sazonal e  $P$  e  $Q$  os graus dos polinômios das respectivas partes. Além disso,  $S$  denota o período sazonal da série, por exemplo,  $S=12$  para séries temporais mensais.

Para aplicação do modelo ARIMA faz-se necessária a execução de um ciclo composto por quatro etapas, quais sejam: identificação, estimação, verificação e previsão (LIMA; CASTRO; CARTAXO, 2019).

Na fase de identificação é estabelecida a ordem do modelo, i.e., são fixados os valores de  $p$ ,  $d$ ,  $q$ ,  $P$ ,  $D$  e  $Q$  que melhor modelam o processo estocástico subjacente à série temporal. A fase de identificação é uma etapa crítica e pode ser realizada por meio da análise das funções de autocorrelação e autocorrelação parcial amostrais da série temporal em estudo. Ainda nesta etapa, deve-se avaliar a necessidade de aplicar diferenças simples e diferenças sazonais para tornar a série estacionária, uma premissa assumida pela abordagem Box & Jenkins (BARROS *et al.*, 2020).

Na sequência, a fase de estimação consiste em obter estimativas dos coeficientes  $\theta$  e  $\phi$  referentes à componente não sazonal e os coeficientes  $\Phi$  e  $\Theta$  inerentes à componente sazonal. Felizmente, o *software* R (R CORE TEAM, 2019) disponibiliza recursos para automação das etapas supracitadas, como as funções *auto.arima* e *Arima* do pacote *forecast* (HYNDMAN; KHANDAKAR, 2008).

A fase de verificação busca avaliar a consistência do modelo, verificando a significância estatística dos coeficientes estimados e se os resíduos do modelo corroboram com a premissa de erros não autocorrelacionados (CAMPOS; CORDEIRO, 2006). Os autores ainda destacam que um critério de escolha entre dois ou mais modelos consiste em analisar os respectivos valores da estatística AIC (*Akaike's Information Criteria*), devendo ser escolhido o modelo com menor AIC. Após a execução das fases anteriores, o modelo estará apto à realização das previsões a partir dos dados da série temporal.

## 2.4. MÉTODO DE HOLT-WINTERS

O método de Holt-Winters é uma das ferramentas estatísticas que viabiliza a obtenção de previsão de demanda a partir de séries temporais, sobretudo aquelas que venham apresentar componentes de tendência e sazonalidade (MORETTIN; TOLOI, 2018). Quanto ao tratamento da influência dos aspectos sazonais, este pode ser abordado na forma aditiva ou multiplicativa (BARROS *et al.*, 2020).

De acordo com Petropoulos, Wang e Disney (2019), este método destaca-se pela simplicidade em sua aplicação e a obtenção de resultados com boa acurácia quando comparados com métodos mais complexos. Conforme Barros *et al.* (2020), a versão aditiva deste método quando do processo de previsão  $m$  passos à frente de uma série temporal mensal ( $m=12$ ), pode ser expressa conforme a Equação 3 a seguir:

$$\hat{y}_{t+m} = a_t + b_t m + S_{T-s+m} \quad (3)$$

cujos coeficientes de tendência ( $a_t$  e  $b_t$ ) e sazonalidade  $S_{t-s+m}$  são atualizados com base nas equações a seguir:

$$a_t = \alpha(y_t - S_{t-s}) + (1 - \alpha)(a_{t-1} + b_{t-1}) \quad (4)$$

$$b_t = \beta(a_t - a_{t-1}) + (1 - \beta)b_{t-1} \quad (5)$$

$$S_t = \gamma(y_t - a_t) + (1 - \gamma)S_{t-s} \quad (6)$$

Nas equações (4), (5) e (6), as respectivas constantes de suavização  $\alpha$ ,  $\beta$  e  $\gamma$  pertencem ao intervalo  $[0,1]$  (TRATAR; STRMCNIK, 2016). Barros *et al.* (2020) complementam que os valores mais próximos de 1 denotam que as observações mais recentes representam um maior peso nas previsões, enquanto que valores que se aproximam de 0 indicam que as observações mais antigas da série exercem maior influência nas previsões. Conforme Morettin e Toloi (2018), as constantes de suavização  $\alpha$ ,  $\beta$  e  $\gamma$ , são calibradas com o objetivo de reduzir os desvios entre a série temporal  $y_t$  e as previsões correspondentes.

## 3. METODOLOGIA

No que concerne aos aspectos metodológicos, conforme Vergara (2010), este estudo apresenta caráter descritivo, por detalhar o processo de previsão de demanda de um item de estoque em uma Organização Militar da MB. Adicionalmente, de acordo com Yin (2015), a pesquisa caracteriza-se como um estudo de caso, haja vista tratar de aspectos peculiares à gestão contábil de alimentos da Marinha do Brasil.

Os dados utilizados para a execução do processo de previsão foram coletados na Diretoria de Finanças da Marinha (DFM), na base de dados do sistema Quaestor. Foi selecionado o arroz como item de estoque de alimentos a ser analisado, tendo em vista que este item apresentou relevância dentre os gêneros secos, quanto ao valor consumido pelas OM da MB no ano de 2019, além de ser um item presente constantemente nos cardápios que compõem os almoços e jantares.

Foram utilizados os dados de consumos mensais do item durante o período de 2014 a 2018 para o ajuste dos modelos preditivos. Os dados referentes aos consumos em 2019 foram utilizados para a comparação com os valores previstos fornecidos pelos modelos de Holt-Winters e ARIMA.

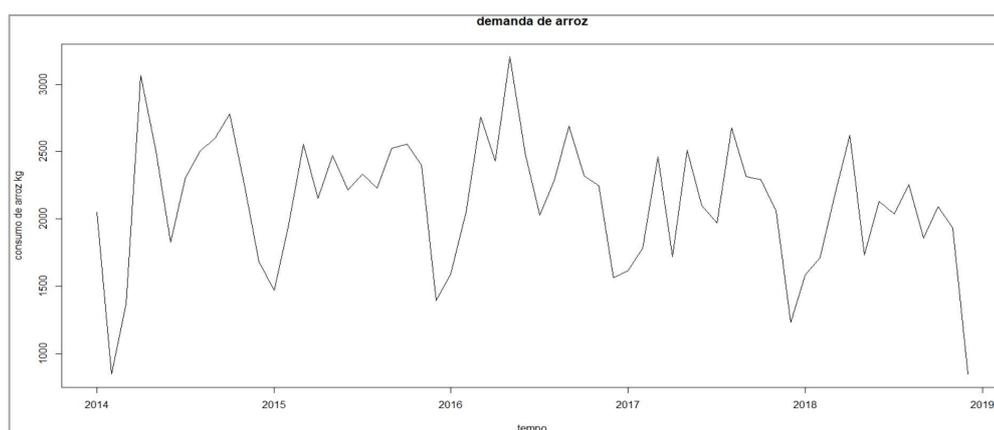
O tratamento dos dados deu-se por meio do *software* R. Mais especificamente, as previsões geradas pelo método de Holt-Winters, foram obtidas pela função *HoltWinters*, enquanto que o ajuste do modelo ARIMA foi realizado com o auxílio das funções *auto.arima* e *Arima*, disponíveis no pacote *forecast* (HYNDMAN; KHANDAKAR, 2008).

#### 4. ANÁLISE DOS RESULTADOS

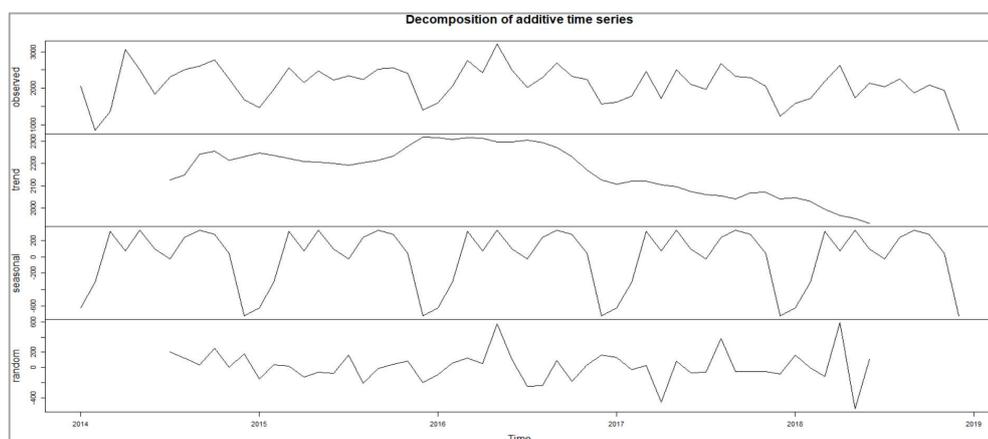
Esta seção apresenta os resultados e análises referentes ao processo de previsão de consumo de arroz em uma OM de ensino da MB para o exercício de 2019.

##### 4.1. ANÁLISE EXPLORATÓRIA DOS DADOS

A série temporal do consumo mensal de arroz durante o período de 2014 a 2018 é ilustrada na Figura 1, cuja característica mais evidente é a sazonalidade aditiva. Adicionalmente, na Figura 2, gerada pela função *decompose*, a decomposição em componentes não observáveis (tendência, sazonalidade e irregular) oferece uma melhor apreciação dos traços estilizados da série temporal analisada.



**Figura 1:** Série temporal de consumo de arroz no período de 2014 a 2018  
**Fonte:** Os autores (2021)



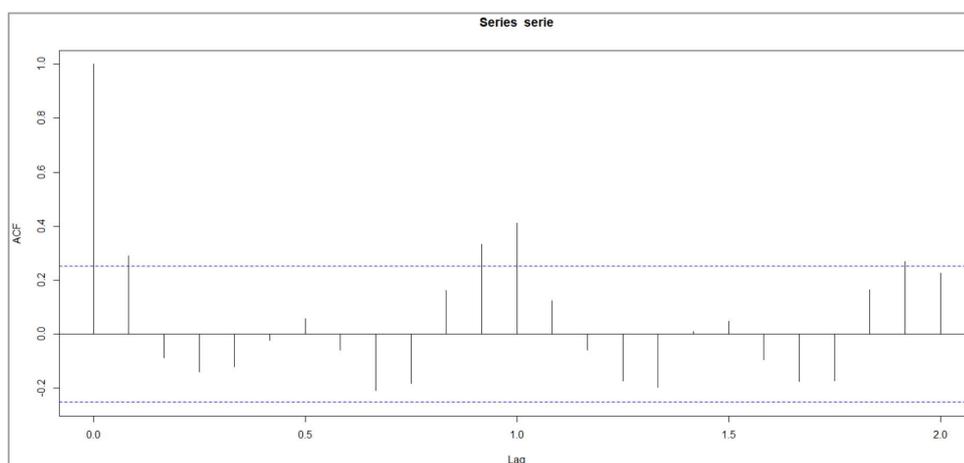
**Figura 2:** Decomposição da série temporal em componentes não observáveis  
**Fonte:** Os autores (2021)

A componente sazonal na Figura 2 revela a redução periódica do consumo de arroz, em dezembro, um padrão compatível com o fato da OM analisada ser uma instituição de ensino, na qual os alunos não realizam suas refeições durante o período de férias escolares no mês de dezembro. Ainda na Figura 2 é possível constatar uma ligeira tendência de redução de consumo de arroz no final do período analisado. Essa observação pode auxiliar o gestor contábil de alimentos quanto aos níveis de estoque a serem adotados, sugerindo a aquisição de quantidades de arroz que sejam coerentes com a tendência da série de consumo deste item na OM analisada.

A seguir serão operacionalizadas as previsões de consumo de arroz para o ano de 2019, com base nos métodos de ARIMA e Holt-Winters.

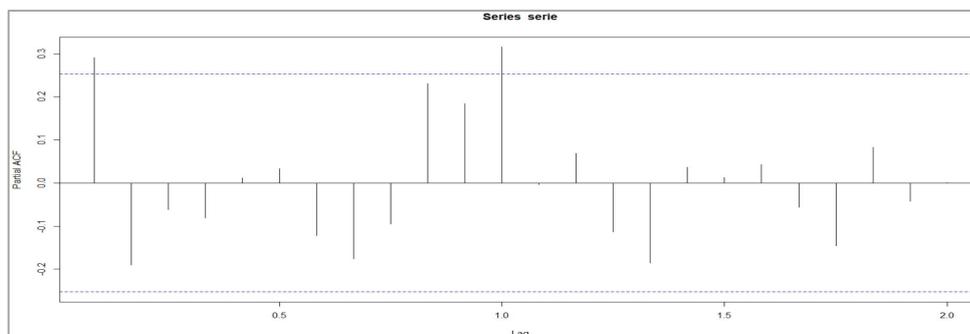
#### 4.2. ANÁLISE DA PREVISÃO COM BASE NO MÉTODO ARIMA

Iniciando os procedimentos de ajuste do modelo ARIMA, foram analisados os gráficos das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) da série em análise, com o propósito de identificar características inerentes à ordem do modelo ARIMA a ser estabelecido. Nas Figuras 3 e 4 estão dispostos os gráficos da FAC e FACP, respectivamente.



**Figura 3:** Função de Autocorrelação da série de consumo de arroz  
**Fonte:** Os autores (2021)

Na Figura 3 é possível observar um decaimento exponencial no gráfico da FAC, indicando que não será necessário tomar a diferença da série temporal para a remoção de tendências. Adicionalmente, observa-se picos sazonais, indicando que o modelo terá em sua composição a componente autorregressiva na parte sazonal. A Figura 4, a seguir, ilustra a FACP da série temporal em análise.



**Figura 4:** Função de Autocorrelação Parcial da série de consumo de arroz  
**Fonte:** Os autores (2021)

A análise da FACP (Figura 4) sugere a identificação da ordem  $P$  da componente autorregressiva sazonal. No caso em lide, observou-se a presença de autocorrelação significativa em  $lag$  1,0, o que possibilita inferir que o modelo possui uma componente autorregressiva na parte sazonal com  $P=1$ .

Posteriormente foram utilizadas as funções *ndiffs* e *nsdiffs* do pacote *forecast*, com o objetivo de identificar, respectivamente, o número de diferenças ( $d$ ) e o número de diferenças sazonais ( $D$ ) que tornam a série analisada estacionária. Nesse caso foi constatado que não há necessidade de efetuar diferenciações, logo  $d=0$  e  $D=0$ , um resultado compatível com a FAC e FACP, ilustradas nas Figuras 3 e 4 respectivamente. Na sequência, utilizou-se a função *auto.arima*, com o objetivo de obter uma especificação inicial para o modelo ARIMA, neste caso, um modelo SARIMA  $(0,0,1) \times (1,0,0)_{12}$ , conforme disposto na Figura 5.

```
> auto.arima(serie)
Series: serie
ARIMA(0,0,1)(1,0,0)[12] with non-zero mean

Coefficients:
      mal      sar1      mean
    0.2869  0.5181 2094.7557
s.e.  0.1712  0.1307  112.2966

sigma^2 estimated as 159557:  log likelihood=-444.92
AIC=897.84  AICc=898.57  BIC=906.22
```

**Figura 5:** Ordem do modelo ARIMA  
**Fonte:** Os autores (2021)

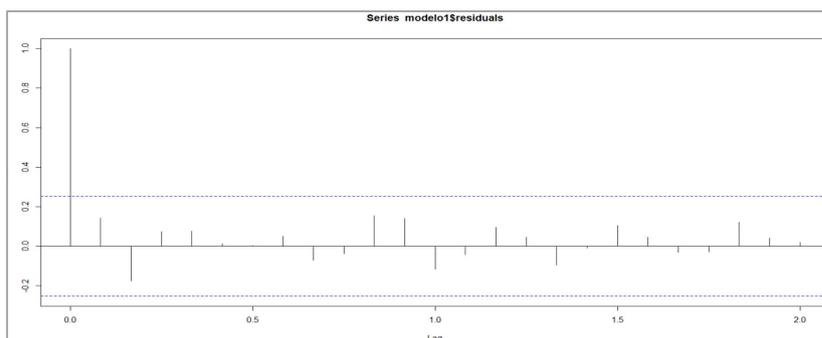
Contudo, no modelo identificado pela função *auto.arima* (Figura 5) o coeficiente da componente média móvel (*ma1*) não tem significância estatística. Assim, visando identificar um modelo parcimonioso e com significância estatística em todos os coeficientes, procedeu-se à realização de testes de sobrefixação com a análise de especificações alternativas, geradas a partir de modificações da especificação inicial SARIMA  $(0,0,1) \times (1,0,0)_{12}$ , conforme indicado na Tabela 1. É possível notar que cada especificação avaliada é acompanhada da respectiva estatística AIC, sendo que o menor AIC corresponde ao melhor modelo (CAMPOS; CORDEIRO, 2006). Logo, nesse caso, o melhor modelo é o SARIMA  $(0,0,0) \times (1,0,0)_{12}$ .

**Tabela 1:** Estatística AIC dos modelos avaliados

Modelo	AIC
SARIMA(0,0,1)x(1,0,0) <sub>12</sub>	897.84
SARIMA(0,0,0)x(1,0,0) <sub>12</sub>	-3.99
SARIMA(0,0,0)x(1,0,1) <sub>12</sub>	-1.99
SARIMA(0,0,1)x(1,0,1) <sub>12</sub>	-2.93
SARIMA(1,0,1)x(1,0,1) <sub>12</sub>	-3.16
SARIMA(0,0,0)x(2,0,0) <sub>12</sub>	-1.99

**Fonte:** Os autores (2021)

Na Figura 6, a Função de Autocorrelação (FAC) dos resíduos do modelo SARIMA  $(0,0,0) \times (1,0,0)_{12}$  revela a ausência de qualquer estrutura de autocorrelação, portanto, o modelo proposto é adequado para a previsão de consumo de arroz no exercício de 2019.



**Figura 6:** Função de Autocorrelação dos resíduos  
**Fonte:** Os autores (2021)

Tendo em vista a escolha do modelo SARIMA(0,0,0)x(1,0,0)<sub>12</sub>, observa-se que este se alinhou às análises realizadas com base na FAC e FACP. A seguir, a Figura 7 dispõe os valores dos coeficientes do modelo utilizado para a obtenção das previsões de consumo de arroz em 2019.

```
> summary(modelo1)
Series: serie
ARIMA(0,0,0)(1,0,0)[12] with non-zero mean
Box-Cox transformation: lambda= 0

Coefficients:
      sar1      mean
    0.6307    7.6080
s.e.  0.1133    0.0574
```

**Figura 7:** Coeficiente autorregressivo da parte sazonal do modelo  
**Fonte:** Os autores (2021)

Através da função *Arima* obteve-se o valor do coeficiente autorregressivo sazonal,  $\Phi=0.6307$  ( $sar1=0.6307$ ), do modelo SARIMA(0,0,0)x(1,0,0)<sub>12</sub> escolhido para a obtenção das previsões mensais, conforme disposto na Figura 7.

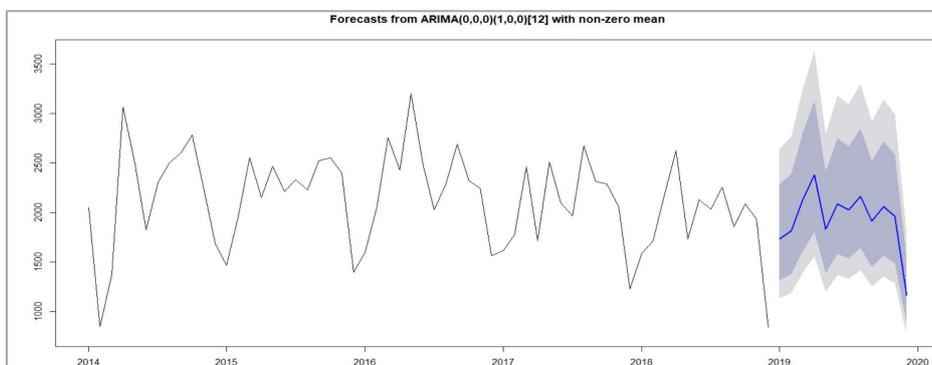
Na Tabela 2 apresentam-se as previsões do consumo de arroz na OM analisada.

**Tabela 2:** Previsão de consumo arroz para 2019 - ARIMA

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	1380	1733,01	25,58%
Fev	1570	1816,56	15,71%
Mar	1650	2123,35	28,69%
Abr	1620	2380,40	46,94%
Mai	1962	1833,26	6,56%
Jun	1648	2086,46	26,61%
Jul	1809	2027,28	12,07%
Ago	2070	2162,88	4,49%
Set	1981	1915,50	3,31%
Out	1941	2061,66	6,21%
Nov	1663	1963,86	18,09%
Dez	905	1164,54	28,68%
<b>TOTAL</b>	<b>20199</b>	<b>23268,76</b>	<b>15,20%</b>

**Fonte:** Os autores (2021)

Conforme disposto na Tabela 2, observa-se que o valor acumulado de consumo estimado de arroz para o ano de 2019 foi de 23.268,76 Kg, valor este que excedeu em 15,20% ao valor observado acumulado naquele ano. Na Figura 8, é possível observar o gráfico da série temporal contendo a previsão de consumo para o ano de 2019 (linha em azul).



**Figura 8:** Previsão de consumo de arroz branco para 2019 – ARIMA

**Fonte:** Os autores (2021)

No gráfico de consumo de arroz ilustrado na Figura 8, observa-se além das previsões mensais de consumo, os limites dos respectivos intervalos de previsão com 95% de confiança (área em cor cinza). A seguir será realizada a análise da previsão dos valores de consumo mensais de arroz com a utilização do método aditivo de Holt-Winters.

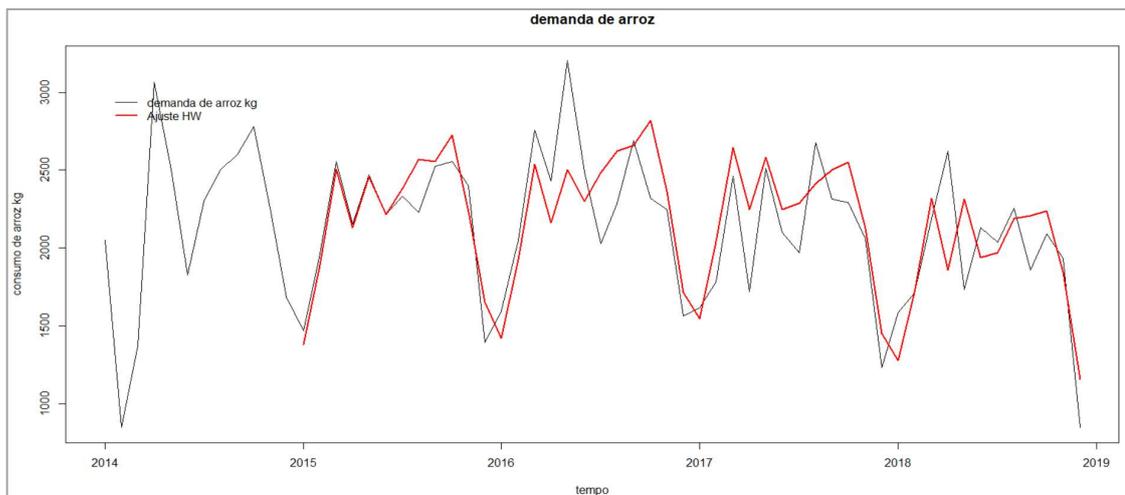
#### 4.3. ANÁLISE DA PREVISÃO COM BASE NO MÉTODO DE HOLT-WINTERS

Inicialmente, por meio da função *HoltWinters*, foram calibradas as constantes de suavização  $\alpha$ ,  $\beta$  e  $\gamma$ , cujos valores ótimos encontram-se na Tabela 3. A qualidade do ajuste resultante pode ser visualizada na Figura 9, na qual apresenta-se a série temporal de consumo de arroz no período de 2014 a 2018 (linha em preto) e as respectivas estimativas obtidas pelo modelo de Holt-Winters (linha em vermelho).

**Tabela 3:** Parâmetros de suavização arroz

Item	alfa	beta	gama
Arroz	0,0458	0,3159	0,1403

**Fonte:** Os autores (2021)



**Figura 9:** Ajuste sazonal de consumo de arroz – 2014 a 2018

**Fonte:** Os autores (2021)

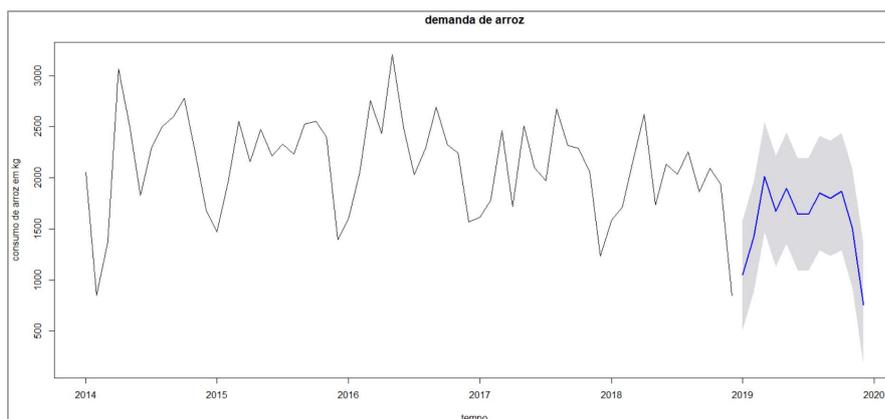
Após o ajuste do modelo preditivo de Holt-Winters, foi obtida a previsão até 12 passos à frente, para o consumo de arroz em uma OM analisada. A Tabela 4 apresenta os valores mensais observados naquele ano, extraídos do Quaestor, e as respectivas previsões calculadas pelo método de Holt-Winters.

**Tabela 4:** Previsão de demanda arroz  
 2019 – Holt-Winters

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	1380	1049,35	23,96%
Fev	1570	1425,29	9,22%
Mar	1650	2008,84	21,75%
Abr	1620	1670,85	3,14%
Mai	1962	1897,83	3,27%
Jun	1648	1643,23	0,29%
Jul	1809	1641,69	9,25%
Ago	2070	1850,02	10,63%
Set	1981	1799,32	9,17%
Out	1941	1865,70	3,88%
Nov	1663	1507,45	9,35%
Dez	905	756,08	16,46%
<b>TOTAL</b>	<b>20199</b>	<b>19115,65</b>	<b>5,36%</b>

**Fonte:** Os autores (2021)

Ao verificar na Tabela 4 a quantidade de consumo de arroz prevista para o ano de 2019, observou-se que o valor se aproximou em 94,64% da quantidade efetivamente consumida naquele ano, apresentando-se como um bom parâmetro para o planejamento dos processos licitatórios da OM. A seguir, a Figura 10 apresenta o gráfico da previsão de consumo para o ano de 2019 (linha em azul).



**Figura 10** – Previsão de consumo de arroz em 2019 – Holt-Winters

**Fonte:** Os autores (2021)

De forma distinta do modelo ARIMA, a previsão gerada pelo método de Holt-Winters segue um movimento decrescente quanto ao consumo do arroz e, portanto, se mostrou mais aderente ao valor verificado.

## 5. CONSIDERAÇÕES FINAIS

Este trabalho objetivou avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para as atividades gerenciais da gestão de estoques de alimentos de Organizações Militares da Marinha do Brasil (MB). Para isto, foi efetuado o processo de previsão de consumo de arroz para o ano de 2019 em uma OM de ensino da Força, utilizando os métodos estatísticos ARIMA e de Holt-Winters, que possibilitaram resultados preditivos com desvios relativos em relação ao consumo anual de 15,20% e 5,36%, respectivamente.

Diante disso, a partir dos resultados, foi possível inferir que a metodologia utilizada pode ser útil às atividades de planejamento e controle dos estoques de alimentos das OM, uma vez que, aspectos como análises das tendências de consumo e períodos sazonais podem subsidiar as tomadas de decisão dos gestores quanto ao ressuprimento dos estoques de alimentos. Em paralelo, os resultados alcançados podem ser utilizados como subsídios na elaboração dos processos licitatórios, atendendo ao disposto na Lei nº 14.133/2021, que prevê a utilização de métodos quantitativos que embasem as quantidades a serem contratadas pela administração pública.

Adicionalmente, os valores previstos de consumo do item de estoque, obtidos através do processo preditivo podem ser utilizados nos cálculos de projeções de custos para o exercício, uma vez que os custos são apurados com base no consumo dos itens.

Em paralelo, a metodologia empregada nesta pesquisa, com base nos métodos ARIMA e de Holt-Winters, pode vir a contribuir com as atividades gerenciais de planejamento e controle dos gestores contábeis de alimentos das OM da MB, haja vista que o sistema Quaestor não possui funcionalidades para a realização de previsões de consumo.

Sugere-se como futuras pesquisas, a realização de previsão de consumo de outros itens de estoques de alimentos em outras Organizações Militares da Marinha do Brasil, como em navios e hospitais, podendo também ser efetuada em outros órgãos do poder público.

## REFERÊNCIAS

- ALENCAR, C. O.; FONSECA, A. C. P. D.** Excelência na gestão pública: a contribuição do controle interno da Marinha do Brasil. *Revista de Gestão*, v. 23, n. 2, p. 172-184, 2016.
- ALVES, C. C.; HOEPERS, E.; CORAZZA, E. J.; SANTOS, G. J.; CRISTOFOLINI, R.; CRUZ, A. C.** Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. *Revista Produção Online*, v. 19, n. 3, p. 1001-1026, 2019.
- BALLOU, R. H.** Gerenciamento na cadeia de suprimentos/logística empresarial. 5. ed. Porto Alegre: Bookman, 2006.
- BARROS, A. C.; MATTOS, D. M.; OLIVEIRA, I. C. L.; FERREIRA, P. G. C.; DUCA, V. E. L. A.** A análise de séries temporais em R: curso introdutório. 1. ed. São Paulo: Atlas, 2020.
- BRASIL**, Lei nº 14.133, de 01 de abril de 2021. Estabelece normas gerais de licitação e contratação para as Administrações Públicas diretas, autárquicas e fundacionais da União, dos Estados, do Distrito Federal e dos Municípios. *Diário Oficial [da] República Federativa do Brasil*, Brasília, DF, 01 abr. 2021.
- BRASIL**. Marinha do Brasil. Secretaria-Geral da Marinha. Normas sobre município – SGM-305. Brasília, DF, 2015. - 1ª Edição - Rev. 2.
- BRASIL**. Marinha do Brasil. Secretaria-Geral da Marinha. Normas sobre o Sistema de Custos da Marinha do Brasil – SGM-307. Brasília, DF, 2020. - 1ª Edição.
- CAMPOS, P. A. C.; CLEMENTE, A.; CORDEIRO, A. A. L.** de. Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo. In: *Anais do Congresso Brasileiro de Custos-ABC*, São Paulo, 2006. Anais..., São Paulo, 2006.
- CHING, Hong Yuh.** Gestão de estoques na cadeia de logística integrada: supply chain. 4. ed. São Paulo: Atlas, 2016.
- HYNDMAN, R. J.; KHANDAKAR, Y.** Automatic time series forecasting: the forecast package for R. *Journal of Statistical Software*, v. 27, n. 3, p. 1-22, 2008.
- LIMA, J. E. C.; CASTRO, L. F. de; CARTAXO, G. A. A.** Aplicação do Modelo SARIMA na Previsão de Demanda no Setor Calçadista. *ID on line REVISTA DE PSICOLOGIA*, v. 13, n. 46, p. 892-913, 2019.
- MACHADO, N.; HOLANDA, V. B.** de. Diretrizes e modelo conceitual de custos para o setor público a partir da experiência no governo federal do Brasil. *Revista de Administração Pública*, 44, n. 4, p. 791-820, 2010.
- MAKRIDAKIS, S.; SPILIOTIS, E.; ASSIMAKOPOULOS, V.** Statistical and machine learning forecasting methods: concerns and ways forward. *PLoS ONE*, v. 13, n. 3, p. 1-26, 2018.
- MELLO, L. S. C. de; CARDOSO, L. F.; PESSANHA, J. F. M.; COELHO, C. U. F.** A utilização de métodos de previsão de demanda nas atividades contábeis da gestão de estoques de alimentos da Marinha do Brasil. In: *CONGRESSO DE ADMINISTRAÇÃO, SOCIEDADE E INOVAÇÃO*, 13., Rio de Janeiro, 2021. Anais..., Rio de Janeiro, 2021.
- MORETTIN, P. A.; TOLOI, C. M. C.** Análises de Séries Temporais. 3. ed. São Paulo: Blucher, 2018.
- PETROPOULOS, F.; WANG, X.; DISNEY, S. M.** The inventory performance of forecasting methods: evidence from the M3 competition data. *International Journal of Forecasting*, v. 35, n. 1, p. 251-265, 2019.
- R DEVELOPMENT CORE TEAM.** R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2019.
- SAAVEDRA-NIEVES, A.** Inventory model: an R Package for Centralized Inventory Problems. *The R Journal*, v. 10, p. 200-217, 2018.
- SANTANA, E. C.; CORRÊA, C. R.** O emprego do Sistema de Informação de Custos (SIC) do governo federal na Marinha do Brasil: uma análise gerencial dos custos no setor público. *Revista Pensar Contábil*, v. 16, n. 61, p. 37-44, 2014.

**SCRIVANO, F. T.; COSTA, P. C. F.; COSTA, J. M.** Uma análise sobre as ferramentas de gestão utilizadas no controle de desperdícios alimentares nos ranchos da Marinha do Brasil. *Acanto em Revista*, v. 7, n. 7, p. 50-66, 2020.

**SOUSA, D. C. F.; CLAUDINO, C. N. Q.; AQUINO, J. T.; MELO, F. J. C.** Utilização de ferramentas gerenciais para o controle de estoques: um estudo de caso de uma empresa do setor alimentício. *Revista Gestão.Org*, v. 15, n. 2, p. 546-563, 2017.

**TRATAR, L. F.; STRMCNIK, E.** The comparison of Holt-Winters method and Multiple regression method: A case study. *Energy Journal*, v. 109, p. 266-276, 2016.

**VERGARA, S. C.** *Projetos e relatórios de pesquisa em administração*. 12. ed. São Paulo: Atlas, 2010.

**YIN, R. K.** *Estudo de caso: planejamento e métodos*. 5 ed. Porto Alegre: Bookman, 2015.