



Universidade do Estado do Rio de Janeiro

Centro de Ciências Sociais

Faculdade de Administração e Finanças

Luiz Sérgio Carvalho de Mello


**Previsão de Demanda no Municciamento das Organizações Militares da
Marinha do Brasil**

Rio de Janeiro

2022

Luiz Sérgio Carvalho de Mello

**Previsão de demanda no Municciamento das Organizações Militares da Marinha do
Brasil**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Ciências Contábeis, da Universidade do Estado do Rio de Janeiro. Área de concentração: Controle de Gestão.

Orientador: Prof. Dr. José Francisco Moreira Pessanha

Rio de Janeiro

2022

CATALOGAÇÃO NA FONTE
UERJ/REDE SIRIUS/BIBLIOTECA CCS/B

M527 Mello, Luiz Sérgio Carvalho de.
Previsão de demanda no município das Organizações Militares da Marinha do Brasil / Luiz Sérgio Carvalho de Mello. – 2022.
166 f.
Orientador: Prof. Dr. José Francisco Moreira Pessanha.
Dissertação (mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Administração e Finanças.
Bibliografia: f. 151-161.

1. Administração pública – Brasil – Teses. 2. Planejamento – Teses. 3. Brasil. Marinha – Teses. I. Pessanha, José Francisco Moreira. II. Universidade do Estado do Rio de Janeiro. Faculdade de Administração e Finanças. III. Título.

CDU 658:351

Bibliotecária: Luciana Zöhrer CRB7/5643

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação.

Assinatura

Data

Luiz Sérgio Carvalho de Mello

Previsão de demanda no Municciamento das Organizações Militares da Marinha do Brasil

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Ciências Contábeis da Faculdade de Administração e Finanças, da Universidade do Estado do Rio de Janeiro. Área de concentração: Controle de Gestão.

Aprovado em 15 de março de 2022.

Banca Examinadora:

Prof. Dr. José Francisco Moreira Pessanha (Orientador)
Faculdade de Administração e Finanças - UERJ

Prof. Dr. Francisco José dos Santos Alves
Faculdade de Administração e Finanças - UERJ

Prof. Dr. Reinaldo Castro Souza
Pontifícia Universidade Católica – PUC - Rio

Rio de Janeiro
2022

DEDICATÓRIA

Dedico esta pesquisa aos meus amados pais, Albino e Vânia, pelo amor e educação que me deram ao longo desta vida.

Aos meus irmãos Larissa e Luan.

À minha esposa Bruna Mello, por todo amor, paciência e carinho em todos os momentos.

À minha filha Rebeca, pelos sorrisos e abraços que me apoiam e me impulsionam a seguir em frente.

AGRADECIMENTOS

Em primeiro lugar agradeço ao Deus da minha vida, por ter me dado saúde, perseverança e entendimento para desenvolver este estudo. Sem o fôlego da vida, a misericórdia e o sustento diário dados por Jesus, não teria chegado até aqui. Toda glória seja dada ao Senhor Jesus. Mais uma vez o Senhor foi fiel!

Aos meus amados pais, Albino e Vânia, por sempre me incentivarem a estudar, mesmo em meio às dificuldades da vida, sempre fizeram o melhor por mim. Sem vocês eu não teria chegado até aqui. Amo vocês!

Aos meus irmãos Larissa e Luan, que sempre torceram por mim e acompanharam a minha caminhada. Muito obrigado! Amo vocês!

À minha amada e querida esposa Bruna, por todo amor, paciência, dedicação e companheirismo em todos os momentos desta caminhada. Seu carinho e parceria foram fundamentais para que eu chegasse até aqui. Te amo!

À minha querida filha Rebeca, por todo o carinho, amor e alegria que me serviram de combustível diariamente. Seus sorrisos e abraços me confortavam em cada momento desta singradura.

À minha sogra Neildes, por sempre acompanhar e torcer por esta vitória. Obrigado por todo apoio, carinho e auxílio nesta caminhada.

Aos meus amigos Pr. Benedito, Fábio e Guilherme, pela torcida, companheirismo e amizade de sempre. Vocês são amigos para todas as horas! Aos colegas do PPGCC da UERJ pelo convívio, compartilhamento de experiências e parceria nos trabalhos e desafios que nos foram impostos ao longo deste período. Muito obrigado!

Ao meu estimado orientador, Prof. Dr. José Francisco Moreira Pessanha, agradeço por sua amizade e dedicação ao longo deste processo. O seu apoio e os ensinamentos ministrados ao longo do curso tornaram a caminhada mais sólida e precisa, sempre ditando a “velocidade” e o “rumo” correto para que eu chegasse em segurança ao “desejado porto”. Foi uma honra poder ser seu orientando. Obrigado e que Deus te abençoe!

Agradeço ao Prof. Dr. Francisco José dos Santos Alves, pela dedicação e esmero no ensino da Contabilidade ao longo do curso. À Prof. Dra. Andréa Paula Osório Duque pela excelência no ensino dos aspectos inerentes ao desenvolvimento da pesquisa científica. Vocês foram fundamentais em toda a caminhada. Muito obrigado!

Ao Prof. Dr. Claudio Ulysses Ferreira Coelho (*in memoriam*) por todo incentivo e ensinamentos ministrados no início do curso.

Aos demais docentes do PPGCC pelos ensinamentos e atividades acadêmicas ministradas ao longo do mestrado, que muito contribuíram para minha formação.

Ao Prof. Dr. Reinaldo Castro Souza pela gentileza e disponibilidade em participar da banca examinadora e pelas contribuições fornecidas no processo avaliativo deste trabalho. Foi um privilégio poder ter tido a sua participação nesta pesquisa. Muito obrigado!

À toda equipe da secretaria do PPGCC, em especial à Samantha, pela cordialidade, disponibilidade e disposição em ajudar em todos os momentos.

Agradeço à Marinha do Brasil, em especial à Diretoria de Finanças da Marinha, pela oportunidade que me forneceu de estudar e me desenvolver academicamente através deste mestrado. Ao Vice-Almirante (RM1-IM) Hugo Cavalcante Nogueira, ao Vice-Almirante (IM) Wagner Côrrea dos Santos, ao Vice-Almirante (IM) Vinícius Lima de Souza, ao Vice-Almirante (IM) Luiz Roberto Basso, ao Contra-Almirante (IM) Nelson Márcio Romaneli de Almeida, e ao Capitão de Mar e Guerra (IM) Esdras Carlos de Santana, por todo incentivo e apoio ao longo do processo do mestrado.

Agradeço aos meus amigos da DFM e de outras OM que torceram pelo meu ingresso neste mestrado, além de todo apoio administrativo e logístico que me forneceram ao longo deste período. Ao Capitão de Fragata (IM) Marcelo Vallim (meu orientador na MB) pelo apoio e acompanhamento ao longo do curso, ao Capitão de Corveta (IM) Mauro Tavares pelas dicas e trocas de experiências, à Capitão de Corveta (IM) Cátia pela amizade e por todo incentivo e apoio, à Capitão de Corveta (T) Isabelle pela amizade e incentivo, à Capitão de Corveta (IM) Ana Medeiros pelo apoio, à Capitão de Corveta (IM) Érica pela troca de experiências e pelo apoio prestado através do CIANB, ao Capitão de Corveta (IM) Escobar pela amizade, torcida e apoio, ao Capitão de Corveta (IM) Botelho pela amizade, apoio e dicas, ao Capitão de Corveta (IM) Fogaça pela amizade e parceria nos trabalhos ao longo do mestrado, ao Suboficial (PL) Cruz pela amizade e apoio durante o curso, ao Primeiro-Sargento (ES) Félix pela disponibilidade e apoio na coleta dos dados, ao Cabo (ES) Damião e Cabo (ES) Guedes por todo apoio administrativo que me prestaram. Vocês fazem parte desta vitória!

Muito obrigado a todos! O sentimento é de, graças a Deus, ter combatido o bom combate, completado esta etapa e por fim, ter guardado a fé!

O homem não pode receber coisa alguma se do céu não lhe for dada.

João 3:27

RESUMO

MELLO, Luiz Sérgio Carvalho de. *Previsão de demanda no Municciamento das Organizações Militares da Marinha do Brasil*, 2022. 173 f. Dissertação (Mestrado em Ciências Contábeis) - Faculdade de Administração e Finanças, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2022.

A busca por maior efetividade nos processos de tomada decisão atinentes à contabilidade pública tem aprimorado e originado novos mecanismos de controle, por exemplo, a elaboração de Estudos Técnicos Preliminares (ETP) para a aquisição de bens e a contratação de serviços e obras no âmbito da Administração Pública Federal direta, autárquica e fundacional, conforme disposto na Instrução Normativa nº 40, de 22 de maio de 2020. Nos ETP devem constar estimativas das quantidades a serem contratadas, acompanhadas das respectivas memórias de cálculo, dos preços unitários e das estimativas do valor da contratação. Neste contexto, a previsão de demanda executada por métodos estatísticos apresenta-se como uma ferramenta gerencial a ser empregada nas atividades da gestão de estoque de alimentos das Organizações Militares da Marinha do Brasil (MB) com a finalidade de alcançar maior assertividade nas aquisições destes itens e consequentemente mitigar os riscos de desperdício de recursos públicos. Sendo assim, o objetivo deste estudo é o de avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para o planejamento e controle do Municciamento das Organizações Militares (OM) da MB. A pesquisa apresenta-se como descritiva e com abordagem quantitativa. Foram utilizados o método de Holt-Winters e a metodologia Box & Jenkins para a execução dos processos preditivos de consumo de seis itens de estoque de alimentos em sete Organizações Militares da MB. Os resultados desta pesquisa apontaram que o método de Holt-Winters, aplicado aos valores mensais acumulados dos últimos 12 meses, apresentou os melhores resultados no que concerne à elaboração dos ETP. Independentemente do método de previsão escolhido, os casos analisados apontam que a aplicação dos métodos estatísticos na previsão de consumo de gêneros alimentícios oferece importantes contribuições para as atividades de planejamento e controle das OM, sobretudo nas projeções de custos de alimentos, na elaboração de informações gerenciais a serem registradas no Sistema de Informação de Custos do Governo Federal (SIC) e na elaboração do Plano de Contratação Anual e dos ETP dos processos de aquisições de alimentos.

Palavras-chave: Previsão de demanda. Gestão de estoques. Marinha do Brasil. Planejamento. Controle.

ABSTRACT

MELLO, Luiz Sérgio Carvalho de. *Demand forecast in the Brazilian Navy's food accounting management*, 2022. 173 f. Dissertação (Mestrado em Ciências Contábeis) - Faculdade de Administração e Finanças, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2022.

The search for greater effectiveness in decision-making processes related to public accounting has improved and given rise to new control mechanisms, for example, the preparation of Preliminary Technical Studies (ETP) for the acquisition of goods and the contracting of services and works within the scope of the direct, autarchic, and foundational federal Public Administration, as provided for in Normative Instruction No. 40, of May 22, 2020. The ETP must contain estimates of the quantities to be contracted, accompanied by the respective calculation logs, unit prices and estimates of the contract value. In this context, demand forecasting performed by statistical methods is a management tool to be used in the Brazilian Navy's (MB) food accounting management activities to achieve greater assertiveness in food purchases and consequently mitigate the risks of wasting public resources. Therefore, the objective of this study is to evaluate how the demand forecasting process, based on statistical methods, can contribute to the planning and control of food accounting management in the MB. The research presents itself as descriptive and with a quantitative approach. The Holt-Winters method and the Box & Jenkins methodology were used to carry out the consumption predictive processes of six food stock items in seven Military Organizations (OM) of the MB. The results of this research showed that the Holt-Winters method, applied to the accumulated monthly values of the last 12 months, presented the best results regarding the elaboration of the ETP. Regardless of the chosen forecasting method, the cases analyzed show that the application of statistical methods in the food consumption forecasting offers important contributions to the planning and control activities of OM, especially in the food cost projections, in the preparation of managerial information to be registered in the Federal Government Cost Information System (SIC) and in the preparation of the Annual Contracting Plan and ETP for food procurement processes.

Keywords: Demand forecast. Inventory management. Brazilian Navy. Planning. Control.

LISTA DE TABELAS

Tabela 1 -	Distribuição das OM.....	40
Tabela 2 -	Gêneros secos com maiores custos em 2019.....	62
Tabela 3 -	Gêneros frigorificados com maiores custos em 2019.....	63
Tabela 4 -	Hortifrutigranjeiros com maiores custos em 2019.....	63
Tabela 5 -	Parâmetros de suavização – arroz.....	66
Tabela 6 -	Previsão de consumo de arroz – 2019 – HW.....	67
Tabela 7 -	Métricas de desempenho.....	67
Tabela 8 -	Previsão acumulada para 2019 – arroz – HW.....	68
Tabela 9 -	Estatística AIC dos modelos avaliados.....	71
Tabela 10 -	Previsão de consumo para 2019 – arroz – BJ.....	73
Tabela 11 -	Métricas de desempenho.....	73
Tabela 12 -	Previsão acumulada para 2019 – arroz – BJ.....	75
Tabela 13 -	Parâmetros de suavização – feijão.....	78
Tabela 14 -	Previsão de consumo para 2019 – feijão – HW.....	79
Tabela 15 -	Métricas de desempenho.....	79
Tabela 16 -	Previsão acumulada para 2019 – feijão – HW.....	80
Tabela 17 -	Previsão de consumo para 2019 – feijão – BJ.....	85
Tabela 18 -	Métricas de desempenho.....	85
Tabela 19 -	Previsão acumulada para 2019 – feijão – BJ.....	87
Tabela 20 -	Parâmetros de suavização – frango – HN.....	90
Tabela 21 -	Previsão de consumo para 2019 – frango – HN – HW.....	91
Tabela 22 -	Métricas de desempenho.....	92
Tabela 23 -	Previsão acumulada para 2019 – frango – HN – HW.....	92
Tabela 24 -	Previsão de consumo para 2019 – frango – HN – BJ.....	96
Tabela 25 -	Métricas de desempenho.....	97
Tabela 26 -	Previsão acumulada para 2019 – frango – HN – BJ.....	99
Tabela 27 -	Parâmetros de suavização – frango – navio.....	101
Tabela 28 -	Previsão de consumo para 2019 – frango – navio – HW.....	102
Tabela 29 -	Métricas de desempenho.....	102
Tabela 30 -	Previsão acumulada para 2019 – frango – navio – HW.....	103
Tabela 31 -	Previsão de consumo para 2019 – frango – navio – BJ.....	107

Tabela 32 -	Métricas de desempenho.....	108
Tabela 33 -	Previsão acumulada para 2019 – frango – navio – BJ.....	109
Tabela 34 -	Parâmetros de suavização – banana.....	111
Tabela 35 -	Previsão de consumo para 2019 – banana – HW.....	113
Tabela 36 -	Métricas de desempenho.....	113
Tabela 37 -	Previsão acumulada para 2019 – banana – HW.....	114
Tabela 38 -	Previsão de consumo para 2019 – banana – BJ.....	117
Tabela 39 -	Métricas de desempenho.....	118
Tabela 40 -	Previsão acumulada para 2019 – banana – BJ.....	119
Tabela 41 -	Parâmetros de suavização – açúcar.....	121
Tabela 42 -	Previsão de consumo para 2019 – açúcar – HW.....	123
Tabela 43 -	Métricas de desempenho.....	123
Tabela 44 -	Previsão acumulada para 2019 – açúcar – HW.....	124
Tabela 45 -	Previsão de consumo para 2019 – açúcar – BJ.....	127
Tabela 46 -	Métricas de desempenho.....	127
Tabela 47 -	Previsão acumulada para 2019 – açúcar – BJ.....	129
Tabela 48 -	Parâmetros de suavização – batata.....	131
Tabela 49 -	Previsão de consumo para 2019 – batata – HW.....	132
Tabela 50 -	Métricas de desempenho.....	132
Tabela 51 -	Previsão acumulada para 2019 – batata – HW.....	133
Tabela 52 -	Previsão de consumo para 2019 – batata – BJ.....	136
Tabela 53 -	Métricas de desempenho.....	137
Tabela 54 -	Previsão acumulada para 2019 – batata – BJ.....	139
Tabela 55 -	Resultados das previsões de consumo dos gêneros alimentícios.....	139
Tabela 56 -	Previsões e MAPE das combinações.....	142
Tabela 57 -	Previsões e desvios anuais das combinações.....	143
Tabela 58 -	Série temporal de consumo de arroz em Kg.....	162
Tabela 59 -	Série temporal de consumo de feijão em Kg.....	162
Tabela 60 -	Série temporal de consumo de frango em Kg – HN.....	163
Tabela 61 -	Série temporal de consumo de frango em Kg – navio.....	163
Tabela 62 -	Série temporal de consumo de banana em Kg.....	163
Tabela 63 -	Série temporal de consumo de açúcar em Kg.....	164
Tabela 64 -	Série temporal de consumo de batata em Kg.....	164

LISTA DE FIGURAS

Figura 1 -	Sistema Quaestor.....	30
Figura 2 -	Distribuição dos CeIM que apoiam navios.....	33
Figura 3 -	Aquisição de gêneros alimentícios pelas OM.....	34
Figura 4 -	Distribuição dos DN no território nacional.....	40
Figura 5 -	Modelo ARIMA.....	49
Figura 6 -	Modelo SARIMA.....	49
Figura 7 -	Série temporal estacionária.....	51
Figura 8 -	FAC com decaimento lento.....	51
Figura 9 -	Ciclo iterativo de previsão ARIMA.....	53
Figura 10 -	FAC com presença de picos e vales.....	54
Figura 11 -	Estratégias de obtenção do modelo ARIMA.....	56
Figura 12 -	Série temporal de consumo de arroz - 2014 a 2018.....	64
Figura 13 -	Decomposição da série temporal do consumo de arroz.....	65
Figura 14 -	Ajuste sazonal do consumo de arroz.....	66
Figura 15 -	Previsão de consumo do arroz para o ano de 2019 - HW.....	68
Figura 16 -	FAC da série de consumo de arroz.....	69
Figura 17 -	FACP da série de consumo de arroz.....	70
Figura 18 -	Ordem do modelo SARIMA - arroz.....	70
Figura 19 -	<i>p-values</i> dos coeficientes estimados - arroz.....	71
Figura 20 -	Gráficos da normalidade dos resíduos do modelo - arroz.....	71
Figura 21 -	FAC dos resíduos do modelo - arroz.....	72
Figura 22 -	<i>p-values</i> do Teste Ljung-Box – arroz.....	72
Figura 23 -	Previsão de consumo de arroz para 2019 - BJ.....	74
Figura 24 -	<i>QQ-plot</i> dos resíduos do modelo ARIMA - arroz.....	75
Figura 25 -	Série temporal de consumo de feijão - 2014 a 2018.....	76
Figura 26 -	Decomposição da série temporal do consumo de feijão.....	77
Figura 27 -	Ajuste sazonal do consumo de feijão.....	78
Figura 28 -	Previsão de consumo de feijão em 2019 – HW.....	80
Figura 29 -	Ordem inicial do modelo SARIMA – feijão.....	81
Figura 30 -	<i>QQ-plot</i> do modelo SARIMA – feijão	82
Figura 31 -	<i>Boxplot</i> da série de consumo de feijão.....	82

Figura 32 -	Ordem do modelo SARIMA - feijão.....	83
Figura 33 -	Gráficos de normalidade dos resíduos do modelo - feijão.....	83
Figura 34 -	FAC dos resíduos do modelo - feijão.....	84
Figura 35 -	<i>p-values</i> do Teste Ljung-Box – feijão.....	84
Figura 36 -	Previsão de consumo de feijão para 2019 - BJ.....	86
Figura 37 -	<i>QQ-plot</i> dos resíduos do modelo SARIMA - feijão.....	86
Figura 38 -	Série temporal de consumo de frango em um HN – 2014 a 2018.....	88
Figura 39 -	Variação do consumo de frango por mês no HN – 2014 a 2018.....	88
Figura 40 -	Decomposição da série temporal de consumo de frango – HN.....	89
Figura 41 -	Ajuste sazonal de consumo de frango – HN.....	90
Figura 42 -	Previsão de consumo de frango para 2019 – HN – HW.....	92
Figura 43 -	FAC da série de consumo de frango – HN.....	94
Figura 44 -	FACP da série de consumo de frango – HN.....	94
Figura 45 -	Ordem do modelo SARIMA – frango – HN.....	95
Figura 46 -	<i>p-values</i> dos coeficientes estimados – frango – HN.....	95
Figura 47 -	Gráficos da normalidade dos resíduos do modelo – frango – HN.....	95
Figura 48 -	<i>p-values</i> do Teste Ljung-Box – frango – HN.....	96
Figura 49 -	Previsão de consumo de frango para 2019 – HN – BJ.....	97
Figura 50 -	<i>QQ-plot</i> dos resíduos do modelo SARIMA – frango – HN.....	98
Figura 51 -	Série do consumo de frango em um navio – 2015 a 2018.....	99
Figura 52 -	Decomposição da série de consumo de frango no navio.....	100
Figura 53 -	Ajuste sazonal do consumo de frango no navio.....	101
Figura 54 -	Previsão de consumo de frango em um navio – 2019 – HW.....	103
Figura 55 -	Ordem do modelo SARIMA – frango – navio.....	105
Figura 56 -	<i>p-values</i> dos coeficientes estimados – frango – navio.....	105
Figura 57 -	Gráficos de normalidade dos resíduos do modelo – frango – navio.....	106
Figura 58 -	FAC dos resíduos do modelo – frango – navio.....	106
Figura 59 -	<i>p-values</i> do Teste Ljung-Box – frango – navio.....	107
Figura 60 -	Previsão de consumo de frango para 2019 em um navio – BJ.....	108
Figura 61 -	<i>QQ-plot</i> dos resíduos do modelo SARIMA – navio.....	109
Figura 62 -	Série temporal de consumo de banana – 2014 a 2018.....	110
Figura 63 -	Decomposição da série temporal de consumo de banana.....	111
Figura 64 -	Ajuste sazonal do consumo de banana.....	112

Figura 65 -	Previsão de consumo de banana para 2019 – HW.....	114
Figura 66 -	Ordem do modelo ARIMA – banana.....	115
Figura 67 -	Gráficos da normalidade dos resíduos do modelo – banana.....	116
Figura 68 -	FAC dos resíduos do modelo – banana.....	116
Figura 69 -	<i>p-values</i> do Teste Ljung-Box – banana.....	117
Figura 70 -	Previsão de consumo de banana para 2019 – BJ.....	118
Figura 71 -	<i>QQ-plot</i> dos resíduos do modelo SARIMA – banana.....	119
Figura 72 -	Série temporal de consumo de açúcar – 2014 a 2018.....	120
Figura 73 -	Decomposição da série temporal de consumo de açúcar.....	121
Figura 74 -	Ajuste sazonal do consumo de açúcar.....	122
Figura 75 -	Previsão de consumo de açúcar para 2019 – HW.....	124
Figura 76 -	Ordem do modelo SARIMA – açúcar.....	125
Figura 77 -	<i>p-values</i> dos coeficientes estimados – açúcar.....	125
Figura 78 -	Gráficos da normalidade dos resíduos do modelo – açúcar.....	126
Figura 79 -	FAC dos resíduos do modelo – açúcar.....	126
Figura 80 -	<i>p-values</i> do Teste Ljung-Box – açúcar.....	126
Figura 81 -	Previsão de consumo de açúcar para 2019 – BJ.....	128
Figura 82 -	<i>QQ-plot</i> dos resíduos do modelo SARIMA – açúcar.....	128
Figura 83 -	Série temporal de consumo de batata – 2014 a 2018.....	129
Figura 84 -	Decomposição da série temporal do consumo de batata.....	130
Figura 85 -	Ajuste sazonal do consumo de batata.....	131
Figura 86 -	Previsão de consumo de batata para 2019 – HW.....	133
Figura 87 -	Ordem do modelo ARIMA – batata.....	134
Figura 88 -	<i>p-values</i> dos coeficientes estimados – batata.....	134
Figura 89 -	Gráficos da normalidade dos resíduos do modelo – batata.....	135
Figura 90 -	FAC dos resíduos do modelo – batata.....	135
Figura 91 -	<i>p-values</i> do Teste Ljung-Box – batata.....	136
Figura 92 -	Previsão do consumo de batata para 2019 – BJ.....	137
Figura 93 -	Ordem do modelo SARIMA – batata.....	138
Figura 94 -	<i>QQ-plot</i> dos resíduos do modelo – batata.....	138
Figura 95 -	Código para obtenção das previsões mensais e acumulada – HW.....	165
Figura 96 -	Código para obtenção das previsões mensais – BJ.....	165
Figura 97 -	Código para obtenção da previsão acumulada – BJ.....	166

Figura 98 - Códigos para obtenção das previsões combinadas..... 166

LISTA DE ABREVIATURAS E SIGLAS

AIC	Critério de Informação de Akaike
ADF	Teste de Raiz Unitária Augmented Dickey Fuller
ARIMA	Modelo Autorregressivo Integrado de Médias Móveis
BJ	Metodologia Box & Jenkins
CCIMAR	Centro de Controle de Inventário da Marinha
CeIM	Centro de Intendência da Marinha
CeIMBe	Centro de Intendência da Marinha em Belém
CeIMLa	Centro de Intendência da Marinha em Ladário
CeIMMa	Centro de Intendência da Marinha em Manaus
CeIMNa	Centro de Intendência da Marinha em Natal
CeIMPL	Centro de Intendência da Marinha em Parada de Lucas
CeIMRG	Centro de Intendência da Marinha em Rio Grande
CeIMSa	Centro de Intendência da Marinha em Salvador
CFN	Corpo de Fuzileiros Navais
CIANB	Centro de Instrução e Adestramento Almirante Newton Braga
CIM	Corpo de Intendentes da Marinha
DFM	Diretoria de Finanças da Marinha
DN	Distrito Naval
ETP	Estudo Técnico Preliminar
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
HN	Hospital Naval
HW	Método de Holt-Winters
IM	Intendente da Marinha
KPSS	Teste de Kwiatkowski-Phillips-Schmidt-Shin
LOA	Lei Orçamentária Anual
MAD	Desvio Médio Absoluto
MAPE	Erro Médio Percentual Absoluto
MB	Marinha do Brasil
MD	Ministério da Defesa
ME	Ministério da Economia

OM	Organização Militar
PAR	Programa de Aplicação de Recursos
PPGCC	Programa de Pós-Graduação em Ciências Contábeis
R	<i>Software</i> estatístico
RMSE	Raiz do Erro Médio Quadrático
SAbM	Sistema de Abastecimento da Marinha
SARIMA	Modelo Autorregressivo Integrado de Médias Móveis com componente Sazonal
SCM	Sistema de Custos da Marinha
SIAFI	Sistema de Administração Financeira do Governo Federal
SIC	Sistema de Informações de Custos do Governo Federal
SGM	Secretaria-Geral da Marinha
TI	Tecnologia da Informação
UERJ	Universidade do Estado do Rio de Janeiro
UG	Unidade Gestora
UGE	Unidade Gestora Executora
UGR	Unidade Gestora Responsável

LISTA DE SÍMBOLOS

\bar{X}	Média
\in	Pertence
\forall	Para todo
Cov	Covariância
p	Ordem do polinômio autorregressivo não sazonal
d	Ordem de diferença não sazonal
q	Ordem do polinômio de médias móveis não sazonal
P	Ordem do polinômio autorregressivo sazonal
D	Ordem de diferença sazonal
Q	Ordem do polinômio de médias móveis sazonal
S	Período da sazonalidade
Kg	Quilogramas
B	Operador de defasagem
t	Instante de tempo
k	Defasagem de tempo
Z	Variável aleatória de uma série temporal
Z_t	Valor observado em um instante de tempo t
\hat{Z}_t	Valor previsto em um instante de tempo t
θ	Coefficiente de média móvel não sazonal
ϕ	Coefficiente autorregressivo não sazonal
Φ	Coefficiente autorregressivo da parte sazonal
Θ	Coefficiente de média móvel da parte sazonal
μ	Média
σ^2	Desvio Padrão
ε_t	Erro aleatório no instante t
E	Valor Esperado
N	Conjunto dos números naturais
α	Parâmetro de suavização para o nível
β	Parâmetro de suavização para a tendência
γ	Parâmetro de suavização para a sazonalidade

<i>L</i>	Componente de nível da série temporal
<i>T</i>	Componente de tendência da série temporal
<i>S</i>	Componente de sazonalidade da série temporal
<i>h</i>	Número de passos à frente a serem previstos
<i>w</i>	Peso atribuído à cada previsão individual na combinação de previsões
<i>f</i>	Previsão individual utilizada na combinação de previsões

SUMÁRIO

	INTRODUÇÃO.....	14
1	REFERENCIAL TEÓRICO.....	20
1.1	Planejamento na administração pública.....	20
1.2	Gestão de estoques.....	24
1.3	Previsão de demanda.....	27
1.4	Municiamento na Marinha do Brasil.....	29
1.5	Teoria dos Contratos.....	34
1.6	Revisão bibliográfica sobre previsão de demanda.....	36
2	METODOLOGIA.....	38
2.1	Método da pesquisa.....	38
2.2	População alvo.....	39
2.3	Coleta dos dados.....	41
2.4	Tratamento dos dados.....	42
2.4.1	<u>Métodos quantitativos para previsão de demanda.....</u>	44
2.4.1.1	Método de Holt-Winters (HW).....	44
2.4.1.2	Metodologia Box & Jenkins (BJ).....	46
2.4.1.3	Combinação de previsões.....	57
2.4.1.4	Medidas de Acurácia.....	60
2.5	Delimitação da pesquisa.....	61
3	ANÁLISE E DISCUSSÃO DOS RESULTADOS.....	62
3.1	Alimentos com maiores custos em 2019	62
3.2	Análise da previsão de consumo de arroz em uma OM de Ensino....	64
3.2.1	<u>Previsão de consumo de arroz baseada no método de Holt-Winters.....</u>	66
3.2.2	<u>Previsão de consumo de arroz baseada na metodologia BJ.....</u>	69
3.3	Análise da previsão de consumo de feijão em uma OM Administrativa.....	76
3.3.1	<u>Previsão de consumo de feijão baseada no método de Holt-Winters.....</u>	77
3.3.2	<u>Previsão de consumo de feijão baseada na metodologia BJ.....</u>	81
3.4	Análise da previsão de consumo de frango em um Hospital Naval.....	87
3.4.1	<u>Previsão de consumo de frango em um HN baseada no método de HW.....</u>	89

3.4.2	<u>Previsão de consumo de frango em um HN baseada na metodologia BJ.....</u>	93
3.5	Análise da previsão de consumo de frango em um Navio.....	99
3.5.1	<u>Previsão de consumo de frango em um navio baseada no método de HW...</u>	101
3.5.2	<u>Previsão de consumo de frango em um navio baseada na metodologia BJ..</u>	105
3.6	Análise da previsão de consumo de banana em uma OM do CFN.....	110
3.6.1	<u>Previsão de consumo de banana baseada no método de Holt-Winters.....</u>	111
3.6.2	<u>Previsão de consumo de banana baseada na metodologia BJ.....</u>	115
3.7	Análise da previsão de consumo de açúcar em uma Base da MB.....	120
3.7.1	<u>Previsão de consumo de açúcar baseada no método de Hol-Winters.....</u>	121
3.7.2	<u>Previsão do consumo de açúcar baseada na metodologia BJ.....</u>	125
3.8	Análise da previsão de consumo de batata em uma OM do CFN.....	129
3.8.1	<u>Previsão de consumo de batata baseada no método de Holt-Winters.....</u>	130
3.8.2	<u>Previsão de consumo de batata baseada na metodologia BJ.....</u>	134
3.9	Análise conjunta dos resultados das previsões.....	139
3.10	Análise das combinações das previsões.....	142
3.11	Análise da aplicação das previsões no SCM.....	144
	CONSIDERAÇÕES FINAIS.....	146
	REFERÊNCIAS.....	151
	APÊNDICE A – Séries temporais de consumo de alimentos.....	162
	APÊNDICE B – Programa computacional empregado.....	165

INTRODUÇÃO

O planejamento nas instituições e a precisão nas tomadas de decisão têm se tornado cada vez mais elementos propulsores na obtenção de resultados eficientes em diferentes atividades da contabilidade pública. Diante deste cenário, a Administração Pública tem buscado metodologias e tecnologias que possibilitem aos gestores realizar previsões, controlar os bens e reduzir custos nas organizações (SOBRAL; NETO, 2020).

Nesse sentido, as ações que envolvem o planejamento nos órgãos públicos têm congregado cada vez mais medidas que visam proporcionar um melhor controle dos aspectos contábeis, sobretudo no acompanhamento dos custos e na elaboração dos orçamentos, visando assim a aplicação dos recursos públicos de forma mais precisa (MACHADO; HOLANDA, 2010; OLIVEIRA JUNIOR, 2020).

Desta forma, o emprego da ciência de dados, associada à tecnologia, como o *Robotic Process Automation* (RPA), pode contribuir para o aperfeiçoamento dos mecanismos de gestão, uma vez que tais ferramentas possibilitam a automação de serviços administrativos vinculados ao planejamento e controle das instituições, bem como a uma maior eficiência nas atividades contábeis (MELLO *et al.*, 2021).

Adicionalmente, ressalta-se a atenção que o setor público tem dispensado ao planejamento e a busca pela precisão nos atos administrativos dos seus órgãos, fato este evidenciado pela recente emissão da Instrução Normativa nº 40 de 2020 do Ministério da Economia (ME), que reforçou e detalhou a necessidade da elaboração dos Estudos Técnicos Preliminares (ETP) quando da aquisição de bens de estoque e da contratação de serviços por órgãos públicos federais da administração direta (ALVES, 2021).

No referido documento, foi possível observar a exigência da realização de estimativas e previsões com base nos históricos de consumo, e que estejam fundamentadas em métodos quantitativos que justifiquem os valores e quantidades a serem inseridos nos termos de referência dos processos licitatórios dos órgãos públicos federais (ME, 2020).

Em seguida, ressalta-se o sancionamento da Lei nº 14.133 de 01 de abril de 2021, conhecida como a “nova lei de licitações e contratos”, que trouxe um enfoque aos aspectos do princípio do planejamento nas contratações públicas. Alinhada à IN nº 40/2020 do ME, evidenciou a necessidade da realização de previsões das quantidades de materiais a serem adquiridos, bem como suas respectivas inclusões no Plano de Contratações Anual e ETP dos órgãos (BRASIL, 2021; MELLO; PESSANHA, 2021).

Com isto, as previsões das quantidades a serem adquiridas pelos órgãos públicos federais passaram a ter maior ênfase no processo de planejamento e controle. A previsão de demanda é definida por Hoover (2021) como o uso de métodos estatísticos que viabilizam o fornecimento de estimativas com base em dados passados e presentes disponíveis.

Nesse sentido, destaca-se que a ênfase dada ao planejamento na administração pública, sobretudo nos processos de contratações, reflete diretamente nos órgãos que gerenciam estoques de materiais a serem utilizados nas suas atividades rotineiras, devendo os gestores efetuarem as devidas previsões de consumo dos itens para cada exercício.

De acordo com Freitas *et al.* (2020), para as organizações que tratam com a gestão de estoques, a previsão de demanda é um elemento fundamental para o planejamento e controle dos níveis de estoques. Os autores ainda ressaltam que as instituições encontram dificuldades para gerir grandes quantidades de itens de estoque, e com isto torna-se essencial a disponibilidade de ferramentas eficientes que possibilitem o desenrolar das ações de planejamento e controle dos gestores.

Nesse diapasão, destaca-se a existência de diversos métodos estatísticos que podem ser utilizados na realização de um processo preditivo, dentre eles alguns clássicos, como o método de Holt-Winters, propício às séries temporais com tendência e sazonalidade, e que proporciona resultados com boa acurácia através de uma execução simples, quando comparado com métodos mais complexos (BARROS *et al.*, 2020; BRANDÃO *et al.*, 2012; PETROPOULOS; WANG; DISNEY, 2019; VEIGA *et al.*, 2014). Em paralelo, pode-se mencionar a metodologia Box & Jenkins, que apresenta robustez, além de ser difundida e conhecida como modelo Autorregressivo Integrado de Média Móvel (ARIMA) (BARROS *et al.*, 2020; HYNDMAN; KHANDAKAR, 2008; LIMA; CASTRO; CARTAXO, 2019; MORETTIN; TOLOI, 2018; MAKRIDAKIS; SPILIOTIS; ASSIMAKOPOULOS, 2018; VEIGA *et al.*, 2014).

Diante das demandas por informações mais precisas, que denotem transparência, controle e precisão na gestão dos recursos públicos, Alencar e Fonseca (2016) enfatizam a necessidade de as instituições públicas proverem os instrumentos e conhecimentos adequados aos seus respectivos gestores, de forma que o desenvolvimento de suas tarefas esteja alinhado aos parâmetros gerenciais cada vez mais modernos, que ora se apresentam.

Nesse contexto, a Marinha do Brasil (MB), como órgão da administração direta do governo federal, possui diversas atividades vinculadas à contabilidade pública, que demandam o cumprimento das normas e exigências legais emitidas pelos órgãos de controle interno e externo a que presta contas.

Dentre as atividades da MB, destaca-se o Muniamento, setor responsável pelo gerenciamento da alimentação nas Organizações Militares (OM) distribuídas em todo o território nacional, cujo contexto abarca a gestão de estoques de gêneros alimentícios (MELLO *et al.*, 2021).

Segundo Scrivano, Costa e Costa (2020), o Muniamento na MB exerce influência em todas as OM da Força, tendo em vista que este setor é responsável por fornecer as refeições diárias aos militares a bordo dos navios e OM sediadas em terra. Além disso, a alimentação trata-se de um fator relevante no cotidiano profissional, uma vez que, exerce influência sobre os aspectos físico e moral dos militares no desenvolvimento de suas atividades laborais (SANTOS *et al.*, 2018).

Nesse cenário, releva mencionar as atribuições do Muniamento, que engloba o gerenciamento da estrutura física e contábil dos alimentos nas OM, devendo os gestores realizar o planejamento das aquisições, a execução dos recursos disponíveis e o controle dos estoques de gêneros alimentícios (MELLO; SANTOS JUNIOR; PESSANHA, 2021). Estas ações devem ser realizadas de forma harmônica, o que demanda à administração da Marinha o fornecimento de alternativas de mecanismos aos seus gestores para o seu correto desenvolvimento.

Sendo assim, o gerenciamento dos estoques de gêneros alimentícios nas OM é uma tarefa a ser executada pelos gestores da Força (BRASIL, 2015), e que, se traduz em um processo de planejamento do armazenamento dos itens em um local específico, bem como seu respectivo controle, além de realização da devida retroalimentação destes itens, baseada no planejamento estabelecido inicialmente (CHING, 2016).

Sousa *et al.* (2017) destacam que, sob o prisma do planejamento, os processos de previsões, executados através de métodos estatísticos, podem contribuir eficazmente para o desenrolar das ações dos gestores. Conforme os autores, este processo pode produzir maior acurácia nas aquisições, além de indicar os períodos sazonais de consumo, o que corrobora para um nível de serviço adequado dos setores frente aos seus clientes, podendo proporcionar um melhor controle dos estoques e impactar na redução dos custos.

Atualmente, a MB, por meio da Diretoria de Finanças da Marinha (DFM), disponibiliza aos gestores das diversas OM distribuídas pelo Brasil, um sistema corporativo denominado Quaestor, que possibilita a realização dos registros inerentes ao controle de entradas e saídas dos gêneros alimentícios em estoque (MELLO; SANTOS JUNIOR; PESSANHA, 2021).

Entretanto, quando da necessidade de realização de previsões de consumo, o Quaestor não dispõe de funcionalidades preditivas. Este aspecto apresenta-se como uma lacuna no

referido sistema, uma vez que as previsões, conforme Alves *et al.* (2019) são mecanismos importantes ao gerenciamento dos estoques, e que impactam nos níveis de serviços prestados.

Tombosi e Dias (2020) alertam que as falhas e lacunas nos processos logísticos das instituições, nas quais se inserem as ferramentas gerenciais que compõem a estrutura de planejamento e controle, são os principais causadores de desperdício de alimentos e de recursos financeiros em muitos órgãos.

Barros *et al.* (2020) trazem à tona que os métodos estatísticos de previsão de demanda, operacionalizados de forma automatizada por meio do *software* R (R CORE TEAM, 2021), podem ser empregados em diferentes análises econômicas e contábeis. Mello e Peternelli (2013) ainda destacam que o *software* R, pode ser obtido de forma gratuita pelas diversas instituições, uma vez que se trata de um *software Open Source*.

Desta forma, este estudo fundamenta-se na Teoria dos Contratos que, segundo Lopes (2004), considera que um determinado processo em uma instituição depende do equilíbrio contratual estabelecido previamente, buscando solucionar incertezas decorrentes da sua execução. Adicionalmente, Pereira *et al.* (2014) destacam a sua relação com os aspectos de controle nas organizações, incluindo nesse escopo a verificação da fundamentação das quantidades e valores contratuais.

Diante deste cenário, formulou-se o seguinte problema de pesquisa: Como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para o planejamento e controle do Municíamento das Organizações Militares da Marinha do Brasil?

A presente pesquisa realiza um estudo em uma OM de Ensino; um Hospital Naval (HN); uma OM Administrativa; um Navio; duas OM do Corpo de Fuzileiros Navais (CFN), e uma Base da MB, que dispõem do Municíamento em sua estrutura administrativa. Conseqüentemente, estas OM possuem a atribuição de gerenciar estoques de gêneros alimentícios, tendo em vista a necessidade de fornecimento diário das refeições em diferentes contextos atrelados às suas respectivas peculiaridades, apresentando assim uma variedade de cenários em que o processo de previsão de demanda pode ser empregado, contribuindo para a temática do estudo.

Quanto à sua relevância, a pesquisa se alinha ao enfatizado por Caetano, Borinelli e Rocha (2019), que destacam a responsabilidade do setor público em prover soluções e ferramentas aos seus gestores, de forma que sejam alcançadas a racionalização e otimização da aplicação dos recursos públicos, gerando assim maior eficiência e eficácia. Esta visão é compartilhada por Silva, Santos e Costa (2016), que mencionam que os métodos de previsão de demanda apresentam-se como opções de ferramentas aos gestores nos processos de

planejamento das instituições, contribuindo para a redução de custos e maior precisão nas tomadas de decisão.

Outro aspecto relevante é a escassez de pesquisas que abordem a previsão de demanda de gêneros alimentícios em OM das Forças Armadas. Com isto, este estudo poderá sugerir a adoção de um mecanismo de previsão de demanda de alimentos, com base em métodos estatísticos, que busque contribuições para a gestão de estoque de alimentos das OM da MB. Adicionalmente, a pesquisa poderá auxiliar na mitigação de riscos de desperdício de alimentos e de recursos públicos, haja vista a materialidade dos recursos orçamentários e financeiros alocados anualmente à MB para o custeio da alimentação dos militares.

Mediante ao problema de pesquisa apresentado, foram estabelecidos o objetivo geral e específicos, conforme especificado abaixo:

OBJETIVO GERAL

- Avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para o planejamento e controle do Municimento das OM da MB.

OBJETIVOS ESPECÍFICOS

- Analisar os dispositivos legais que dispõem de exigências que possam ser atendidas pelo processo de previsão de demanda operacionalizado por meio de métodos estatísticos;
- Analisar sete processos de previsão de demanda de itens de estoque de alimentos com maiores custos em 2019, em seis tipos de Organizações Militares da MB, com base nos métodos de Holt-Winters e ARIMA;
- Analisar a combinação de previsões obtidas pelos métodos de Holt-Winters e Box & Jenkins;
- Analisar como as previsões obtidas podem contribuir para o Sistema de Custos da Marinha (SCM) no contexto do Municimento da MB; e

- Identificar os aspectos gerenciais advindos do processo de previsão de demanda, passíveis de serem aplicados pelos gestores no planejamento e controle dos estoques de alimentos das OM da MB.

A dissertação em lide apresenta a seguinte estrutura: além desta introdução, o primeiro capítulo dispõe de um referencial teórico que aborda os temas relacionados ao planejamento na administração pública; à gestão de estoques; à previsão de demanda; ao Municíamento na MB; à Teoria dos Contratos e uma revisão bibliográfica de estudos anteriores que abordem a previsão de demanda de itens de estoques. Na sequência, o segundo capítulo especifica a metodologia empregada na dissertação, com o detalhamento dos métodos estatísticos de previsão de Holt-Winters e ARIMA. O terceiro capítulo apresenta a análise e discussão dos resultados encontrados após o emprego dos processos preditivos nos itens de estoques de OM da MB. Na sequência são realizadas as considerações finais. Os apêndices apresentam as tabelas contendo as séries de consumo dos gêneros alimentícios e os *scripts* utilizados no *software* R, quando da execução das diversas etapas dos processos de previsão realizados na pesquisa.

1 REFERENCIAL TEÓRICO

Para consecução do objetivo estabelecido nesta pesquisa, este capítulo dispõe dos aspectos teóricos que sustentam o estudo, e estão distribuídos em cinco seções, quais sejam: planejamento na administração pública; gestão de estoques; previsão de demanda; Municípios na Marinha do Brasil; Teoria dos Contratos e os estudos anteriores sobre previsão de demanda em gestão de estoques.

1.1 Planejamento na administração pública

Sousa, Batista e Andrade (2004) definem o planejamento como a forma de programar e administrar o futuro, levando em consideração as consequências e mudanças que podem ocorrer diante da realidade, além das influências advindas dos aspectos orçamentários e financeiros de uma organização.

O planejamento na área pública deve englobar objetivos, metas e princípios, meios de realização e mecanismos de avaliação e controle, gerando benefícios à sociedade, uma vez que sem o planejamento, o poder público não consegue efetuar a aplicação dos recursos públicos de forma adequada (CASIMIRO; MORAES, 2017).

Silva *et al.* (2018) acrescentam que o planejamento é um princípio previsto na Constituição Federal de 1988 e se estabeleceu como um dos elementos primordiais à gestão pública. Ao longo do tempo, outros dispositivos trouxeram destaque a este princípio, sobretudo na esfera das contratações públicas, cabendo enfatizar os seguintes: Lei Complementar nº 101/2000 (Lei de Responsabilidade Fiscal); Lei nº 10.520/2002 (Pregão para aquisições de bens e serviços comuns); Lei nº 8.666/1993 (Lei de licitações e contratos); Decreto nº 10.024/2019 (Pregão Eletrônico); e recentemente a Lei nº 14.133/2021, conhecida como “a nova lei de licitações e contratos”, que trouxe uma maior ênfase ao princípio do planejamento na administração pública, além de dispor dos regramentos para a elaboração do Plano de Contratação Anual e do Estudo Técnico Preliminar (ETP) (MELLO; PESSANHA, 2021).

Dentre os elementos que subsidiam os gestores no planejamento dos órgãos da administração pública estão as informações fornecidas pela contabilidade, haja vista que por

meio delas são conduzidas as aplicações dos recursos públicos na busca pela observância aos princípios da eficiência e eficácia (BRANDALISE; FELLA; ZAMIN, 2009).

Amorim e Souza (2019) mencionam que, diante das dificuldades das contas públicas brasileiras na última década, especificamente a partir do exercício de 2013, a administração pública tem buscado um encadeamento dos instrumentos e mecanismos que compõem o planejamento na esfera pública. Desta forma, diante do cenário de austeridade fiscal a que o País tem enfrentado nos últimos anos, os gestores têm sido instados cada vez mais a prestarem contas acerca da aplicação dos recursos públicos, o que ressalta a importância dos instrumentos de planejamento e controle como balizadores dos gastos das instituições públicas (OLIVEIRA JUNIOR, 2020).

Santana e Corrêa (2014) ressaltam que, para o efetivo cumprimento de metas estabelecidas no planejamento governamental, se faz necessária a implementação de sistemas de custos e de controle nos órgãos da esfera pública. Machado e Holanda (2010) acrescentam que as informações de custos vinculadas aos benefícios que as políticas públicas trazem à sociedade, deveriam ser utilizadas como parâmetros para a elaboração do orçamento, que se trata de um instrumento que viabiliza a execução das despesas planejadas.

Nesse contexto, Santana e Corrêa (2014) mencionam o Sistema de Informações de Custos do Governo Federal (SIC) como uma importante ferramenta de apoio à gestão utilizado pelos órgãos públicos. O SIC traz como suas principais finalidades a possibilidade de produzir informações de custos que possam ser utilizadas pelos órgãos de planejamento e orçamento do governo, quando do processo avaliativo de alocação de recursos públicos, sendo essencial ao processo de planejamento e orçamentação, além de proporcionar uma melhora nas informações internas gerenciais em processos decisórios das organizações (MACHADO; HOLANDA, 2010).

Os custos apurados em uma atividade trazem um elo aos aspectos orçamentários, e com isto, as estimativas de custos baseadas nos parâmetros do SIC, que considera o regime de competência para a apuração dos custos, permitem projetar a necessidade de recursos para que estes custos sejam suportados, refletindo desta forma na previsão de recursos orçamentários para o cumprimento de uma determinada atividade de um órgão público (BORGES; MARIO; CARNEIRO, 2013).

Com isto, quando se aborda o planejamento de contratações de itens de estoque de um órgão público, o histórico de consumo, conforme as diretrizes do SIC, indica os custos daqueles itens em um determinado período, e não a movimentação monetária empregada para a sua aquisição, ensejando assim na possibilidade de previsão de recursos necessários a serem

alocados para as aquisições do exercício subsequente, o que torna a previsão de demanda uma ferramenta primordial ao planejamento das instituições públicas, e que reflete nas atividades contábeis gerenciais de custos e orçamento (BRASIL, 2020; MACHADO; HOLANDA, 2010; MELLO; SANTOS JUNIOR; PESSANHA, 2021).

Costa, Braga e Andrioli (2017) reportam que a ineficiência na administração pública brasileira não é inerente somente aos problemas de fraude e corrupção, mas também à má gestão nas contratações públicas. De acordo com os autores, a deficiência no planejamento é o principal fator motivador das fragilidades dos processos de aquisições públicas. Alinhado a este entendimento, Mendes (2012) ressalta que o sucesso ou não da contratação, ou seja, o atendimento de forma eficiente e eficaz da necessidade da administração depende estritamente da realização de um bom planejamento.

Justen Filho (2021) destaca que o planejamento adequado das contratações nos órgãos públicos, possui como principais finalidades o delineamento da necessidade, a escolha da solução mais benéfica à administração no que tange os aspectos qualitativos e quantitativos, bem como a identificação dos custos e riscos que envolvem a contratação.

Cabe destacar que os materiais e suprimentos utilizados pelos órgãos públicos são essenciais à execução eficiente dos serviços prestados à sociedade, e são adquiridos por meio dos processos desenvolvidos pelo setor de compras das instituições, devendo estes contemplar aspectos de planejamento e controle, sobretudo para os itens de estoque (HOFFMANN, 2011).

Desta forma, visando enfatizar o planejamento no setor público, recentemente, o Ministério da Economia emitiu a Instrução Normativa nº 40, de 22 de maio de 2020, que reforçou este princípio no âmbito da administração pública, uma vez que, o referido documento disciplinou e detalhou a elaboração dos Estudos Técnicos Preliminares (ETP), estabelecendo-o como o documento pertencente à primeira etapa do planejamento das contratações em um órgão do governo federal (ALVES, 2021; ME, 2020; MELLO *et al.*, 2021).

Os ETP possuem como finalidade analisar a viabilidade técnica, socioeconômica e ambiental das contratações, objetivando subsidiar os gestores nas tomadas de decisão inerentes às contratações, além de fundamentar o termo de referência do processo licitatório (ALVES, 2021; SOBRAL, NETO; 2020).

Adicionalmente, como inovação, a IN nº 40/2020 apresentou a ferramenta de TI chamada “Sistema ETP digital”, que passou a ser disponibilizada no Portal de Compras do Governo Federal, sendo destinada aos gestores quando da elaboração dos ETP e do correspondente registro no referido sistema informatizado (ALVES, 2021; ME, 2020).

Para Costa, Braga e Andrioli (2017), o ETP é um documento essencial ao planejamento das aquisições públicas, além de se configurar como uma ferramenta de controle, que contempla a realização de previsões de demanda dos itens a serem adquiridos, reduzindo os riscos de emissão de aditivos contratuais desnecessários e até mesmo de novos processos licitatórios, o que acarreta perdas de economia de escala.

A mencionada atenção dispensada pela administração pública ao planejamento das contratações se coaduna ao mencionado por Ballou (2006), quando destaca que o planejamento e o controle nas atividades logísticas de uma organização possuem dependência das estimativas acuradas dos itens a serem utilizados, o que torna a previsão de demanda uma essencial ferramenta de planejamento e controle na contabilidade.

Mais recentemente, a Lei nº 14.133/2021 dispõe em seu art. 18, § 1º, de algumas ações que evidenciam o planejamento das contratações, em específico no que concerne à elaboração do Plano de Contratação Anual e do ETP (BRASIL, 2021), documentos que deverão conter os seguintes elementos:

- I - descrição da necessidade da contratação, considerando o problema a ser resolvido sob a perspectiva do interesse público;
- II - demonstração da previsão da contratação no plano de contratação anual, sempre que elaborado, de modo a indicar seu alinhamento com o planejamento da Administração;
- III - requisitos da contratação;
- IV - estimativas das quantidades para a contratação, acompanhadas das memórias de cálculo e dos documentos que lhes dão suporte, que considerem interdependência com outras contratações, de modo a possibilitar economia de escala.

Adicionalmente, o art. 40 da lei nº 14.133/2021 estabelece que o planejamento das compras deverá pautar-se na expectativa de consumo anual, ou seja, as quantidades totais de contratação deverão estar alinhadas à quantidade total prevista para o consumo do item (BRASIL, 2021). O item III do referido artigo da lei traz destaque a este aspecto:

- III – determinação de unidades e quantidades a serem adquiridas em função de consumo e utilização prováveis, cuja estimativa será obtida, sempre que possível, mediante adequadas técnicas quantitativas, admitido o fornecimento contínuo.

Nesse sentido, a lei destaca que o processo de elaboração dos referidos documentos exige a realização das previsões das quantidades dos itens de estoque a serem adquiridos pelos órgãos, baseadas nos históricos de consumo dos itens, além da fundamentação dos resultados com a utilização de métodos quantitativos (BRASIL, 2021). Conforme exposto por Casimiro e Moraes (2017), cabe à Administração Pública realizar ações pautadas no planejamento, com base em dados concretos, utilização de técnicas, e definição de estratégias que levem em consideração às projeções de custos e de recursos.

Nesse diapasão, o Tribunal de Contas da União (TCU) tem demonstrado exigências aos órgãos fiscalizados no que tange ao estrito cumprimento das ações de planejamento nas contratações públicas, cabendo destaque para os itens de estoque. No Acórdão nº 1.425/2021 – 2ª Câmara, o TCU analisou um processo de aquisição de gêneros alimentícios em uma Organização Militar subordinada ao Ministério da Defesa (MD), e constatou como irregularidade o fato de o citado processo não conter a previsão de demanda detalhada que embasasse as quantidades dos itens a serem adquiridas, bem como para a respectiva projeção dos preços (TCU, 2021).

No exercício de 2020, o TCU, por meio do Acórdão nº 4.039/2020 – Plenário, trouxe recomendações à uma universidade federal, no sentido de se fazer cumprir o envolvimento dos representantes dos diferentes setores no processo de planejamento das compras dos materiais de estoques da instituição, sobretudo na elaboração do Plano de Contratação Anual, de forma que fossem inseridas as previsões das quantidades dos itens a serem adquiridas no exercício subsequente (TCU, 2020).

Sendo assim, as aquisições de materiais para o ressurgimento de estoques de órgãos públicos dependem de um planejamento adequado para a gestão destes itens, o que torna obrigatória, de acordo com os dispositivos legais em vigor, a utilização das ferramentas quantitativas de previsões na elaboração dos documentos que sustentam as contratações dos itens, quais sejam, o Plano de Contratação Anual e o ETP.

Na próxima seção serão detalhados os aspectos acerca da gestão de estoques em organizações.

1.2 Gestão de estoques

Freitas *et al.* (2020) enfatizam que as organizações militares carregam o pioneirismo da utilização da logística de forma estratégica, principalmente pelo fato de realizarem o planejamento das estratégias de gestão dos recursos a serem empregados em operações militares, incluindo os processos de compras e a administração dos estoques.

A gestão de estoques é uma atividade relacionada aos aspectos da logística, que por sua vez, é oriunda da experiência militar ao longo da Segunda Guerra Mundial, ocasião em que foram realizados diversos processos de aquisições e fornecimentos de materiais utilizados pelas

Forças Armadas dos Estados Unidos da América, com o objetivo de efetuar o suprimento necessário ao longo das operações de guerra (BALLOU, 2006; CHING, 2016; POZO, 2010).

Vislumbrando o detalhamento do significado de gestão de estoques, Saavedra-Nieves (2018) define o estoque como sendo o armazenamento de certa quantidade de itens em um momento específico, e que expressam um capital imobilizado na forma destes produtos. Ballou (2006) acrescenta que o estoque também pode ser definido como o acúmulo de matérias-primas, suprimentos e produtos acabados que surgem no nível canal de suprimento de uma instituição. Complementarmente, Moreira (2012) o define como certa quantidade de bens físicos que se traduzem como matérias-primas ou produtos acabados prontos para serem utilizados em uma organização, enquanto Freitas *et al.* (2020) consideram os estoques como sendo os materiais armazenados numa instituição com o propósito de atender à um determinado tipo de demanda.

Santos e Oliveira (2016) ressaltam que o gerenciamento de estoques deve envolver diferentes departamentos em uma organização, cabendo destaque para o setor de compras e o financeiro, o que se coaduna com as recomendações emitidas pelo TCU em ações de fiscalização em órgãos públicos (TCU, 2020). O autor destaca que a sincronização das atividades entre esses setores proporciona uma melhor utilização dos recursos e reduz os riscos de desperdícios de recursos e materiais.

Diante da impossibilidade de se conhecer a demanda futura exata, e das incertezas quanto às entregas dos produtos pelos fornecedores em determinados momentos, a manutenção do estoque mostra sua importância às instituições devido a possibilidade de se manter disponíveis certas quantidades de itens que podem ser empregados em momentos críticos, sem a necessidade da espera da entrega dos materiais pelos fornecedores (BALLOU, 2006).

Releva mencionar que a gestão de estoques congrega as ações dos gestores em prol dos melhores resultados para as instituições, inclusive no setor público, em que há uma busca constante pela eficiência e eficácia na aplicação dos recursos públicos (SILVA; RABELO, 2017). Desta forma, Hoffmann (2011) alerta quanto aos perigos de uma gestão de estoque ineficiente, que pode impactar na distribuição dos materiais e causar prejuízos aos serviços prestados por uma instituição. O autor ainda menciona que a possível falta de itens de estoque em organizações públicas apresenta um risco de comprometimento aos serviços prestados à sociedade.

De acordo com Jacob Júnior *et al.* (2018), o planejamento e o controle do estoque são vertentes primordiais à sua respectiva gestão e buscam um equilíbrio que promova o atendimento dos pedidos e a imobilização de capital adequado. Segundo Ching (2016) e Melo, Frujuelle e Braga (2016), o planejamento consiste em determinar as quantidades de itens que o

estoque possuirá ao longo do tempo, além de estimar os períodos do fluxo de entrada e saída destes, enquanto o controle consiste nas ações de registro dos dados reais das entradas e saídas dos itens em estoque, um aspecto fundamental para minimizar os riscos de quebras de estoque e desperdícios. Desta forma, a gestão de estoques é definida como sendo o planejamento que engloba a previsão de entradas e saídas de itens no estoque, bem como dos períodos os quais sejam necessários os devidos ressuprimentos (CHING, 2016; SANTOS; OLIVEIRA, 2016).

Nesse escopo, Freitas *et al.* (2020) destacam que no âmbito da administração pública, os órgãos devem realizar o planejamento e controle dos seus materiais balizados por critérios rigorosos, que acabam por refletir nas aquisições dos itens de estoque, em virtude da observância aos dispositivos legais que disciplinam o patrimônio público. De acordo com os autores, em muitos casos estes processos podem retardar o ressuprimento dos itens devido à carga administrativa envolvida em suas respectivas execuções. Vale destacar que diferentemente do setor privado, em que os materiais estocados podem ser vendidos ou utilizados na transformação de outros produtos, os estoques de materiais dos órgãos públicos são empregados essencialmente no desenvolvimento de serviços e na concessão de bens, estando vinculado às atividades desenvolvidas pelo órgão (MATIAS; CAMPELLO, 2000).

Para Ballou (2006), o controle de estoques deve atuar de forma a abranger a disponibilidade de certa quantidade de itens alinhada às flutuações de demanda ao longo do tempo, devendo estas tarefas serem executadas e acompanhadas por ferramentas gerenciais informatizadas. Nesse sentido, Freitas *et al.* (2020) reforçam que este controle deve proporcionar às organizações, um nível de estoque condizente com as necessidades de seus respectivos clientes, sem a ocorrência de falta ou excesso de estoque. Este entendimento se alinha ao disposto na Lei nº 14.133/2021, quando esta menciona que a contratação dos itens deve ser em quantidades que retratem a realidade da necessidade de cada órgão (BRASIL, 2021).

Ching (2016) complementa que uma das principais características do planejamento e controle de estoque é a necessidade de realizar as previsões de demanda, antecipando-se às possíveis mudanças que porventura venham ocorrer, e tomando as ações necessárias às correções.

Conforme observado por Martins e Alt (2009), há uma diferenciação entre demanda e consumo. A demanda está atrelada ao desejo do cliente em requisitar o item no estoque, entretanto, esse desejo pode não ser atendido plenamente. Quando o pedido requisitado é atendido em sua totalidade, diz-se que a demanda se igualou ao consumo. Quando do não atendimento de um pedido devido a indisponibilidade de um determinado item, tem-se uma

demanda reprimida. Assim, a previsão de demanda se apresenta como um dos maiores desafios enfrentados pelas organizações na gestão de estoques (FREITAS *et al.*, 2020).

Adicionalmente, Melo *et al.* (2021) ressaltam que o gerenciamento de estoques está intrinsicamente ligado ao controle dos custos de uma instituição, além de refletir no nível de atendimento aos clientes. Esta premissa se alinha ao mencionado por Mello, Santos Junior e Pessanha (2021), quando trazem à baila a relação do volume de consumo dos itens de estoque em organizações públicas com os custos apurados e lançados no Sistema de Informação de Custos do Governo Federal (SIC).

Cabe destacar que em alguns tipos de organizações, o estoque de segurança ou estoque de reserva, faz-se necessário para cobrir possíveis flutuações que venham acarretar atrasos nas entregas, tais como greves, aumento do consumo de um determinado item ou a rejeição de um lote de compra, tendo em vista que esses fatores podem refletir no nível de serviço prestado pelo órgão (MELO *et al.*, 2021; POZO, 2010). Na próxima seção serão abordados aspectos sobre a previsão de demanda.

1.3 Previsão de demanda

A Doutrina de Logística Militar do MD destaca que a previsão de demanda, como princípio logístico, envolve análises sobre o provável curso das necessidades de pessoal, material, equipamentos e serviços, além da forma como ocorrerá a provisão destes (BRASIL, 2016).

Segundo Pochiraju e Seshadri (2019) e Sagaert *et al.* (2018), a quantificação da demanda futura nos órgãos públicos é um elemento de suporte ao planejamento das aquisições e que normalmente fundamenta-se na modelagem dos padrões históricos de consumo com a premissa de que os padrões existentes continuarão no futuro, o que conforme Lazarin *et al.* (2019) e Enami *et al.* (2020) se traduz nos modelos de séries temporais.

A previsão de demanda é uma das principais aplicações da análise e previsão de séries temporais, um campo da pesquisa que abrange diversas áreas de conhecimento e recebe notório destaque, tendo em vista que possibilita o fornecimento de previsões quando não há a disponibilidade de um modelo matemático referente ao objeto de estudo ou quando este se apresenta de forma parcial (GUIMARÃES; FONSECA; RUSSO, 2015).

Caso o gerenciamento do estoque possua inconsistências no processo de previsão da demanda, a organização estará suscetível ao risco de realizar compras em quantidades excessivas, aumentando o capital imobilizado em estoque, bem como o risco da realização de compras em quantidades inferiores às demandadas pelos setores solicitantes, o que pode acarretar prejuízos ao nível de serviço da organização (SOUSA *et al.*, 2017).

A demanda varia ao longo do tempo como fruto do crescimento ou decréscimo das taxas de consumo dos itens, da sazonalidade do padrão da demanda, bem como por conta das oscilações causadas por fatores externos (BALLOU, 2006). Assim, as demandas podem ser classificadas como regular ou irregular.

Ghiani, Laporte e Musmanno (2004) mencionam que para que a previsão tenha boa acurácia, a demanda deve apresentar certo grau de regularidade. Ballou (2006) define a demanda regular como aquela cuja série temporal pode ser decomposta nas componentes de tendência, sazonalidade e aleatórias, desde que as variações aleatórias (ruído) expressem apenas uma pequena parcela da variação restante da série temporal.

No que tange aos métodos de previsão de demanda, Werner (2019) destaca que independentemente do método adotado, o objetivo é o de se obter previsões com a melhor acurácia possível. Entretanto, Ghiani, Laporte e Musmanno (2004) recomendam o emprego de técnicas de previsão que sejam as mais simples possíveis, haja vista a maior facilidade de se obter entendimento e disseminar explicações. Adicionalmente, Makridakis, Spiliotis e Assimakopoulos (2018) ressaltam que os métodos e modelos de previsão, por melhor ajustados que estejam aos dados da amostra de treinamento, não necessariamente resultarão em previsões mais precisas.

Em um sistema de previsão, Silva, Santos e Costa (2016) sugerem que os gestores adotem pelo menos dois métodos estatísticos nos processos preditivos das organizações, haja vista que esta estratégia poderá reduzir as distorções entre os resultados estimados e observados. Os autores ainda destacam que a comparação dos resultados obtidos por mais de um método viabiliza a realização de melhores análises, e por conseguinte, melhores informações prestadas no processo de tomada de decisão.

Hoover (2021) destaca que embora o processo de previsão traga inúmeros benefícios à uma organização, ainda existe muita resistência em diversas instituições no que concerne à adoção de um sistema preditivo para seus negócios. O autor ainda menciona que este fato acarreta pouca ou quase nunca adoção de métodos estatísticos de previsão por essas organizações, sob a justificativa de que a implementação de um sistema de previsão é caro e

demanda grandes conhecimentos de *softwares* estatísticos, o que exigiria um conhecimento técnico profundo de seus gestores.

Nesse sentido, cabe destacar a existência de *softwares* estatísticos que podem ser obtidos de forma gratuita pelas instituições, como o *software* R, e que em sua estrutura oferece ferramentas customizadas para processos preditivos, automatizando métodos clássicos empregados no campo das previsões, além de fornecerem resultados gerenciais para as tomadas de decisão nas áreas de contabilidade e finanças (BARROS *et al.*, 2020; ENAMI; LEAL; GRANZOTTO, 2020; MARTÍNEZ *et al.*, 2019; MELLO; PETERNELLI, 2013; SILVA *et al.*, 2017; VEIGA *et al.*, 2014).

1.4 Municiamiento na Marinha do Brasil

Conforme a Doutrina de Logística Militar do Ministério da Defesa, o Municiamiento da Marinha está inserido nos aspectos logísticos da Força, que contempla um conjunto de atividades voltadas à previsão e provisão dos recursos necessários à execução das missões constitucionais da instituição (BRASIL, 2016).

O Municiamiento é o setor integrante da Função Logística Suprimento da Força, que trata das atividades administrativas e contábeis que visam o fornecimento das refeições diárias aos militares e servidores civis que trabalham nas Organizações Militares (OM) sediadas em terra e nos navios (SCRIVANO; COSTA; COSTA, 2020).

Nesse contexto, estão inseridos os mecanismos de suprimentos de alimentos às diferentes Organizações Militares distribuídas em todo o território nacional que disponham da estrutura do Municiamiento, ou seja, desenvolva atividades de compras, armazenamento e distribuição dos alimentos para o fornecimento das refeições diárias dos militares e servidores civis (BRASIL, 2015).

O Municiamiento possui como atribuições planejar e executar as compras dos gêneros alimentícios, gerenciar os respectivos estoques, bem como elaborar os cardápios e realizar o fornecimento das refeições nas OM da MB (MELLO; SANTOS JUNIOR; PESSANHA, 2021). Desta forma, cada OM que possui a estrutura do Municiamiento detém um estoque de gêneros alimentícios, que é definido por Saavedra-Nieves (2018) como uma certa quantidade de itens que se encontram armazenados num determinado instante e se traduzem em um montante de capital imobilizado na organização.

Atualmente, o referido setor da MB é regido por uma norma interna denominada “SGM-305 – Normas sobre Municciamento”, que versa sobre os regramentos a serem executados pelos gestores que trabalham no setor de alimentação das OM da MB (BRASIL, 2015).

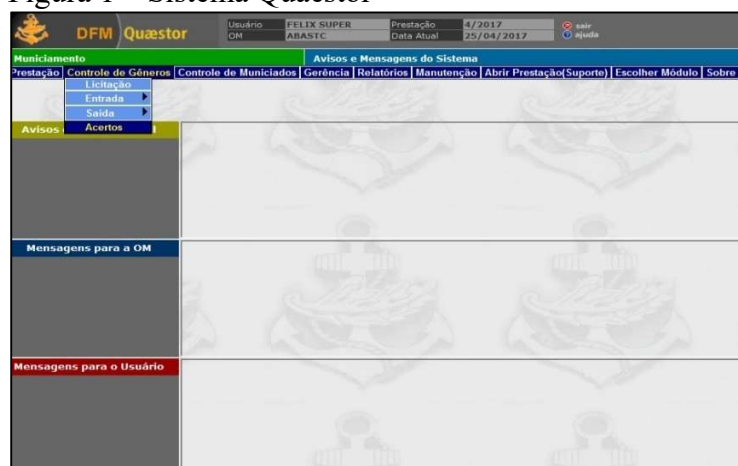
Para a realização do controle da movimentação dos itens de estoque, bem como dos recursos destinados às aquisições destes, a MB dispõe de um sistema corporativo denominado Quaestor, que é utilizado pelos gestores nas escriturações contábeis do setor de alimentação, sobretudo para o controle dos estoques (MELLO; SANTOS JUNIOR; PESSANHA, 2021).

O sistema Quaestor foi desenvolvido pela Marinha em 2007 em substituição ao sistema MUNIC, seu predecessor, que era empregado nas OM desde os anos 1990 (MELLO *et al.*, 2021). Ainda de acordo com os autores, o Quaestor trouxe como fator diferenciador a possibilidade de integrar dados e padronizar procedimentos, tornando o fluxo de informações tempestivo e com maior acessibilidade pelas OM integrantes do sistema de controle interno da Força, sobretudo a Diretoria de Finanças da Marinha (DFM) e o Centro de Controle Interno da Marinha (CCIMAR).

O sistema MUNIC, que até então era utilizado para o controle dos fluxos de entradas e saídas dos gêneros alimentícios em estoques, possuía algumas limitações, dentre elas o fato de ser utilizado de forma local, sem acesso à *intranet*, dificultando assim o envio das prestações de contas ao CCIMAR e o acompanhamento dos aspectos contábeis da gestão de alimentos realizado pela DFM (BRASIL, 2015).

A Figura 1 ilustra a *interface* do Quaestor acessada pelos gestores da MB para o controle dos itens de estoque.

Figura 1 – Sistema Quaestor



Fonte: BRASIL, 2015.

No contexto da gestão de estoques de alimentos, o Quaestor viabiliza aos gestores das OM o registro das entradas e saídas dos gêneros alimentícios em estoques, bem como a emissão

de relatórios que indiquem a posição física e contábil desses itens (MELLO *et al.*, 2021). Adicionalmente, a ferramenta detém funcionalidades para o controle do número de pessoas que realizarão as refeições em cada dia do mês, além de permitir o controle dos saldos de recursos para a aquisição e consumo dos itens. O limite de custos referente ao consumo dos alimentos em um determinado período é denominado internamente pela nomenclatura “Despesa Autorizada” (BRASIL, 2015).

O Quaestor é gerenciado pela Diretoria de Finanças da Marinha (DFM), que é a setorial contábil da Força perante a Secretaria do Tesouro Nacional (STN) (SANTANA; CORRÊA, 2014). Além disso a DFM desenvolve as normatizações atinentes ao Municciamento, que possui como uma das atribuições o gerenciamento do banco de dados do sistema (BRASIL, 2015).

Cabe destacar que o histórico de consumo dos itens de estoque de gêneros alimentícios, permanecem armazenados no banco de dados do Quaestor na DFM. Entretanto, uma das limitações do sistema é o fato deste não possuir funcionalidades que permitam a realização de previsão de demanda baseadas nos referidos históricos (MELLO *et al.*, 2021).

No que concerne à sua utilização, todas as OM sediadas em terra utilizam-se do sistema. Entretanto, ainda se encontra em andamento o processo de implantação da referida ferramenta de TI nos navios da MB, sendo ressaltadas as peculiaridades operativas e as dificuldades de acesso à *intranet* durante as viagens, o que tem acarretado a postergação da utilização do MUNIC por muitos destes (BRASIL, 2015).

No que tange aos recursos orçamentários para a aquisição dos alimentos nas OM das Forças Armadas, cabe destacar que a previsão legal deste tipo de despesa está disposta na Lei Orçamentária Anual (LOA), cujo desdobramento apresenta a Ação Orçamentária 212B, que contém o Plano Orçamentário “Alimentação de Militares em Rancho”, e que expõe detalhadamente a distribuição dos recursos destinados à alimentação nos órgãos militares sob a esfera do Ministério da Defesa (MD) (BRASIL, 2014).

Nesse contexto, baseada na previsão de recursos orçamentários para o custeio das refeições no âmbito da MB, a Administração Naval planeja e executa a distribuição destes montantes às OM sediadas em terra e aos navios, utilizando-se de mecanismos internos para o cálculo dos valores a serem alocados à cada OM (MELLO; SANTOS JUNIOR; PESSANHA, 2021).

Scrivano, Costa e Costa (2020) destacam a existência da chamada “etapa comum de alimentação”, que é empregada para o balizamento do cálculo dos montantes distribuídos às OM para o custeio das refeições. Nesse sentido, um dia de trabalho de um militar corresponde ao direito de o setor contábil de alimentos da OM escriturar uma etapa comum de alimentação

como receita (BRASIL, 2015), que atualmente equivale ao valor de R\$ 9,00 (nove reais) por pessoa.

De acordo com Silva (2016), para o abastecimento dos estoques de alimentos, as OM sediadas em terra dispõem de duas possibilidades de aquisições. A primeira opção se traduz nas compras junto às empresas do ramo alimentício, cujas obtenções são oriundas de processos de contratações realizados pela própria OM.

A segunda possibilidade consiste no recebimento de alimentos por meio do Sistema de Abastecimento da Marinha (SAbM), que através do Centro de Obtenção da Marinha no Rio de Janeiro (COMRJ) executa as compras centralizadas, e posteriormente, o Depósito de Suprimentos de Intendência da Marinha no Rio de Janeiro (DepSIMRJ) e os Centros de Intendência da Marinha (CeIM) executam a distribuição dos itens às OM solicitantes (TONACIO JÚNIOR; VERGARA, 2021).

No contexto da estrutura do SAbM, ressalta-se que antes da fase de aquisição dos itens, executada pelo COMRJ, o Centro de Controle de Inventário da Marinha (CCIM) realiza as previsões de demanda dos itens de estoque da linha de fornecimento do SAbM, dentre os quais se encontram os gêneros alimentícios (MIRANDA, 2014; SILVA, 2016).

No que tange às aquisições de alimentos para os navios, cabe destacar que a Secretaria-Geral da Marinha (SGM) estabeleceu, por meio de suas Diretorias Especializadas competentes, uma nova dinâmica de aquisição de gêneros alimentícios para estes, cuja execução das contratações passaram a ser centralizadas e executadas pelos CeIM distribuídos em sete localidades do País. Este procedimento passou a vigorar em 01 de janeiro de 2020, conforme publicado na Circular nº 17/2020 da DFM.

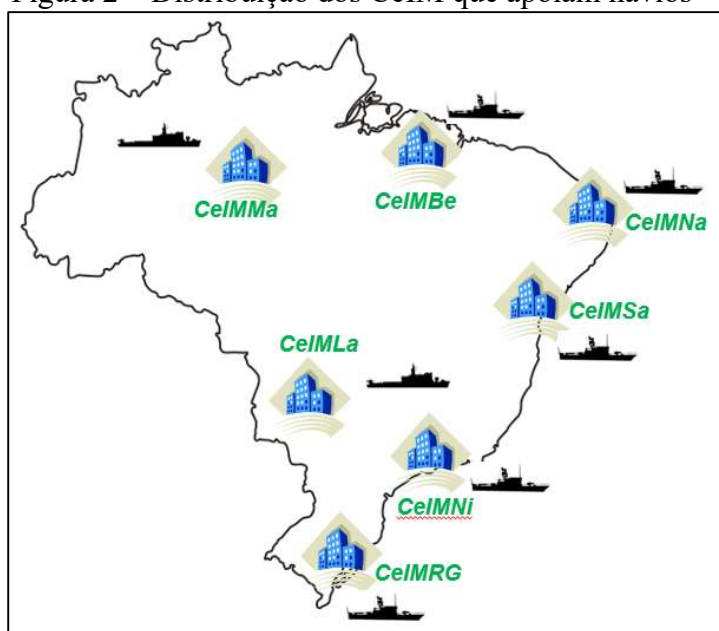
Os CeIM, além de distribuírem os itens oriundos do SAbM, passaram a executar todo o processo de aquisição dos alimentos junto aos fornecedores, que anteriormente era executado pelos gestores dos navios. Nesse escopo, inclui-se a centralização das aquisições para os navios de suas respectivas áreas, realizando assim licitações que abarquem as necessidades de um conjunto de navios (BRASIL, 2015).

Dessa forma, destaca-se que os CeIM pertencem à estrutura organizacional da SGM, estabelecidos regionalmente e atuam logisticamente como Unidades Gestoras Executoras (UGE) dos navios, ou seja, executam os créditos orçamentários no Sistema de Administração Financeira do Governo Federal (SIAFI), alocados para o custeio da alimentação nos navios, que por sua vez, para efeito de registro contábil no SIAFI, representam as chamadas Unidades Gestoras Responsáveis (UGR) (AMORIM; SOUZA, 2019).

As atas de registro de preços (ARP) das categorias de gêneros alimentícios consumidas pelos navios (gêneros secos, gêneros frigorificados e hortifrutigranjeiros) passaram a compor as quantidades estimadas para o atendimento dos navios de área de atuação dos CeIM. Com isto, são geradas Notas de Empenho, na classificação Global, emitidas pelos CeIM (UGE) para cada navio (UGR).

A Figura 2 a seguir dispõe da distribuição geográfica dos CeIM que passaram a centralizar as atividades de aquisições de gêneros do Municíamento dos navios da MB, quais sejam: Centro de Intendência da Marinha em Rio Grande (CeIMRG); Centro de Intendência da Marinha em Niterói (CeIMNi); Centro de Intendência da Marinha em Ladário (CeIMLa); Centro de Intendência da Marinha em Salvador (CeIMSa); Centro de Intendência da Marinha em Natal (CeIMNa); Centro de Intendência da Marinha em Belém (CeIMBe); e Centro de Intendência da Marinha em Manaus (CeIMMa). Cabendo destaque ao CeIMNi, que executa os processos de contratações de alimentos para os navios da Esquadra Brasileira, que é composta pelos navios de grande porte da Marinha.

Figura 2 – Distribuição dos CeIM que apoiam navios



Fonte: MARINHA DO BRASIL, 2021.

A Figura 3 ilustra o processo de aquisição de alimentos realizado pelas OM sediadas em terra que possuem a estrutura do Municíamento e pelos CeIM, quando das aquisições para os navios. De uma forma geral, os gestores identificam as necessidades de ressurgimento dos estoques e consultam os saldos nas atas de registro de preços (ARP), para posterior solicitação junto ao fornecedor e entregas efetuadas por estes (SILVA, 2016).

Figura 3 – Aquisição de gêneros alimentícios pelas OM



Fonte: SILVA, 2016.

Cabe destacar que as quantidades de cada item a serem inclusas nas ARP, quando do planejamento das licitações, devem estar alinhadas ao Programa de Aplicação de Recursos (PAR), que se traduz em um documento que compõe a fase de planejamento das aquisições para o exercício e como um instrumento de monitoramento e avaliação da gestão da OM (BRASIL, 2015). Este documento é previsto na lei de licitações e contratos, e é denominado Plano de Contratações Anual (BRASIL, 2021).

Adicionalmente, menciona-se a participação do Municíamento da MB na estrutura do Sistema de Custos da Marinha (SCM), que é responsável por consolidar as informações de custos a serem inseridas no Sistema de Informações de Custos do Governo Federal (SIC) (BRASIL, 2020; SANTANA; CORRÊA, 2014).

Nesse contexto, o Municíamento exerce influência nos custos apurados, principalmente no que tange à sua gestão de estoques, cujos montantes referentes ao consumo de alimentos, ou seja, das saídas dos estoques, são registrados como custos no período de competência analisado (BRASIL, 2020; MACHADO; HOLANDA, 2010).

1.5 Teoria dos Contratos

Cardoso *et al.* (2021) ressaltam o empenho dos autores que desenvolvem pesquisas no ramo da Contabilidade em ampliar o escopo das explicações dos fenômenos contábeis com base na utilização de teorias que possam corroborar para esta finalidade.

Adicionalmente, Iudícibus *et al.* (2020) alertam quanto ao fato de a Contabilidade não possuir uma teoria própria, o que torna necessária a utilização de outras teorias que possam suportar e fundamentar as pesquisas que tratam sobre os aspectos contábeis. Complementarmente, Dias Filho (2008) enfatiza a capilaridade de atuação da contabilidade em

diversos ramos da sociedade, o que impulsiona os pesquisadores a adotarem teorias de diversas áreas para a sustentação teórica das pesquisas em contabilidade.

Silva, Silva e Borges (2015) destacam que as teorias são elementos que contribuem para a geração do conhecimento científico. Nesse sentido, Soeiro e Wanderley (2019) acrescentam que as pesquisas em contabilidade estão fundamentadas num processo que envolve uma descoberta, interpretação e transmissão dos conhecimentos gerados à sociedade, de forma que esta possa desfrutar dos seus benefícios.

Nesse contexto, a Teoria dos Contratos apresenta-se como uma das possíveis teorias que podem ser empregadas em estudos da área da contabilidade, visando contribuir para a explicação de fenômenos contábeis. Iudícibus e Lopes (2012) destacam que a referida teoria considera uma organização como um conjunto de contratos entre os participantes, que estão relacionados ao sucesso dos processos da instituição, desde que seja atingido o equilíbrio contratual.

Pereira *et al.* (2010) relatam que no escopo da Teoria dos Contratos, a Contabilidade pode atuar gerando informações quanto ao grau de sucesso do cumprimento dos contratos. Ainda segundo os autores, as informações geradas pela contabilidade também podem exercer influência na redução dos custos de negociação dos referidos atos administrativos.

Uma das características mais importantes da Teoria dos Contratos é a sua relação com os aspectos de controle nas instituições, uma vez que os contratos precisam ser monitorados, tornando necessária a ação de fiscalização quanto às quantidades e valores inseridos nas disposições contratuais, buscando evidenciar se os procedimentos utilizados são difundidos no âmbito da ciência (PEREIRA *et al.*, 2010).

Desta forma, a Teoria dos Contratos pode trazer a sustentação teórica necessária aos estudos baseados em previsões a partir de séries temporais, haja vista que os resultados preditivos, baseados em métodos estatísticos difundidos, podem dimensionar as quantidades de itens de estoque que um órgão público visa adquirir, podendo trazer maior eficiência e eficácia na aplicação dos recursos públicos, bem como maior precisão na elaboração dos contratos. Além disso, a automação de um processo de previsão pode trazer contribuições para a esfera do controle interno dos órgãos, tendo em vista que o balizamento das quantidades dos itens de estoque a serem consumidas em um determinado período reduz o risco da necessidade de emissão de novos contratos e de violação das reais necessidades do órgão, pressupostos estes inseridos no contexto da mencionada teoria.

1.6 Revisão bibliográfica sobre previsão de demanda

Esta seção apresenta uma amostra de algumas pesquisas que utilizaram as técnicas de previsão de demanda na gestão de estoque em diferentes tipos de organizações, apontando diversos resultados gerenciais no planejamento e controle de alguns tipos de materiais.

A pesquisa desenvolvida por Carvalho (2018) contemplou a previsão de demanda de materiais de saúde na Marinha do Brasil. Na pesquisa o autor realizou a aplicação de diferentes métodos de previsão de demanda em itens de estoque de materiais de saúde. A partir dos resultados das previsões, avaliou-se possíveis métodos a serem empregados na cadeia de suprimentos de material de saúde, em substituição ao procedimento utilizado até aquele momento.

A previsão de demanda de itens de estoque também é abordada no estudo desenvolvido por Enami, Leal e Granzotto (2020), cujo foco englobou o planejamento de demandas de medicamentos hospitalares, cujos resultados apresentaram melhor acurácia através do método de Holt-Winters. A pesquisa apresentou sua relevância devido o processo de previsão refletir nos impactos que os mencionados materiais podem trazer ao tratamento de pacientes, bem como nos custos operacionais envolvidos.

Fonseca, Santos e Lima (2019) desenvolveram a pesquisa voltada à previsão de demanda intermitente na cadeia de sobressalentes da Marinha do Brasil (MB). No escopo do estudo, foram realizadas previsões de demanda de itens de estoque de sobressalentes de máquinas e motores da MB, empregando diferentes métodos estatísticos de previsão que possam ser implementados no sistema corporativo da instituição desenvolvido para o controle desse tipo de material.

Jacob Junior *et al.* (2018) trazem à baila um estudo sobre previsão de demanda em uma distribuidora de bebidas e bomboniere em Brasília, no Distrito Federal, em que os autores realizam um estudo que abarca a utilização de métodos quantitativos de previsão para os itens de estoque da organização, de forma que fosse possível projetar as demandas mensais e empregar análises gráficas como recursos gerenciais no processo de tomada de decisão dos processos de compras dos gêneros alimentícios.

O estudo desenvolvido por Reis *et al.* (2019) traz uma análise da previsão de demanda na gestão de estoque referente ao setor de hortifruti de um mercado de bairro, utilizando-se de técnicas de previsão e de controle de estoques. Diante da complexidade de se gerir o grupo de itens de estoque que engloba frutas, legumes e verduras, a pesquisa buscou avaliar, a partir dos

métodos de previsão de demanda, os níveis de estoque necessários à redução de custos de manutenção do estoque e da falta de atendimento aos pedidos dos clientes. Como resultado, foi possível estimar um estoque de segurança que atendesse a demanda e minimizasse os custos de não atendimento aos clientes.

Santos e Alves (2017) realizaram uma pesquisa que envolveu a previsão de demanda de um produto de estoque de um supermercado na cidade de Marabá, no Pará. O estudo apresentou processos preditivos de um item do setor varejista de alimentos. Dentre os resultados, o método de Holt-Winters foi o que deteve a melhor acurácia. Como principais contribuições, os autores mencionam que a pesquisa trouxe aspectos de planejamento e controle aos estoques da empresa, que podem ser adotados a partir do processo de previsão de demanda baseado em métodos quantitativos.

Veiga *et al.* (2014) desenvolveram um estudo voltado à previsão de demanda de um grupo de laticínios perecíveis, com um ciclo de vida curto, em uma empresa varejista do ramo de alimentação do sul do Brasil. Foram realizadas previsões com a utilização dos métodos de Holt-Winters e ARIMA, o que possibilitou a comparação dos resultados obtidos para aquele tipo de atividade. O método de Hol-Winters foi o que deteve os melhores resultados na mencionada pesquisa.

Werner (2019) apresenta um estudo de previsão de demanda de leite cru industrializado em uma empresa do Rio Grande do Sul, cujo teor engloba a utilização dos métodos de Holt-Winters e ARIMA, bem como a combinação dos resultados oriundos destes. A pesquisadora constatou que combinações de previsões podem trazer ganhos gerenciais nos estudos de demanda da instituição e para a economia do estado do Rio Grande do Sul, uma vez que o referido estado é o segundo maior produtor de leite cru industrializado do Brasil.

Zanella, Vieira e Barichello (2015) abordam a previsão de demanda em uma agroindústria de carnes do oeste catarinense, no município de Chapecó, estado de Santa Catarina, e evidenciou a importância e essencialidade da utilização de processos preditivos no planejamento dos cenários produtivos, financeiros e de pessoal no curto prazo.

Desta forma, esta amostra de estudos voltados à previsão de demanda de itens de estoque demonstra a importância do tema na área do planejamento e controle dos estoques, incluindo neste contexto a previsão de demanda de alimentos em diferentes organizações.

No próximo capítulo serão abordados os aspectos metodológicos desta pesquisa.

2 METODOLOGIA

Este capítulo apresenta a descrição dos procedimentos metodológicos adotados para a execução da pesquisa, sendo composto por quatro seções: método da pesquisa; população alvo; coleta de dados; e tratamento dos dados. A delimitação do estudo está disposta na quinta seção deste capítulo.

2.1 Método da pesquisa

Miguel (2007) relata que a dinâmica de interação que envolve o pesquisador e o ambiente pesquisado, e que se traduz pela coleta e análise de dados, carece de uma sustentação adequada por meio de métodos específicos à cada natureza de pesquisa, bem como à realidade investigada.

Nesse sentido, Guerra (2010) menciona que a metodologia está relacionada ao estudo dos métodos, enquanto o método denota a maneira ordenada de se proceder em uma pesquisa, além de expandir a concepção ao como proceder no desenvolvimento de um estudo científico.

Nesse escopo, Silva e Menezes (2001) descrevem o ato de pesquisar como a busca por respostas para questões propostas. Adicionalmente, os autores definem a pesquisa científica como a execução de uma investigação que fora previamente planejada e cujo desenvolvimento se deu em consonância às normas consagradas que versam sobre a metodologia científica.

Alinhado à esta visão, Malhotra (2012) destaca que a pesquisa consiste em uma fundamentação para que um estudo seja realizado, em que os procedimentos necessários à sua consecução podem ser verificados com o propósito de obtenção das informações essenciais ao seu desenvolvimento, o que torna importante a escolha do método de pesquisa no desenvolvimento de uma pesquisa científica.

Diante disso, com o propósito de alcançar o objetivo estabelecido pelo estudo, qual seja avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para o planejamento e controle do Municíamento da MB, a pesquisa se configura de natureza descritiva.

No que se refere à abordagem do problema, conforme Malhotra (2012), a pesquisa é definida como quantitativa. A referida abordagem se estabelece devido ao interesse em se obter as respostas de pesquisa por meio da análise de processos de previsão de demanda de itens de estoque de alimentos em seis tipos de Organizações Militares da Marinha do Brasil, cuja execução se vale de métodos estatísticos de previsão de demanda a partir de dados históricos de consumo dos itens.

2.2 População alvo

Para a realização da pesquisa em lide foi escolhido como órgão público a Marinha do Brasil (MB), que se trata de uma instituição subordinada ao Ministério da Defesa (MD).

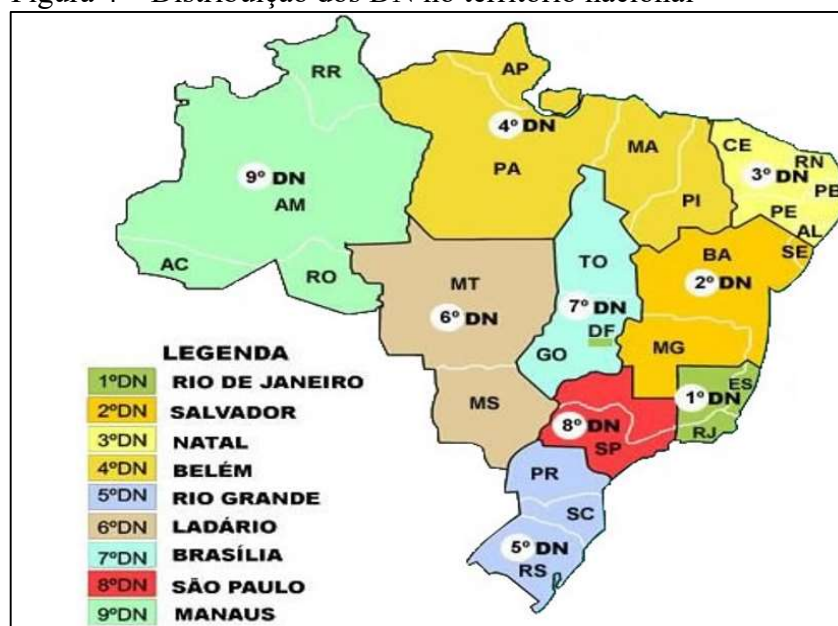
A população alvo deste estudo é definida por 193 Organizações Militares (OM), dentre as quais 101 são OM sediadas em terra e 92 são navios. As 193 OM possuem a estrutura do Municionamento e gerenciam estoques de gêneros alimentícios, requerendo anualmente o planejamento de seus respectivos gestores para o ressuprimento contínuo dos itens, cujas compras são baseadas nos processos licitatórios anuais (BRASIL, 2015).

A fim de manter a transparência e a fidedignidade das informações coletadas, serão preservados em sigilo os nomes das OM analisadas na pesquisa, que serão chamadas de OM de Ensino, OM Administrativa, Hospital Naval (HN), Navio, OM do Corpo de Fuzileiros Navais (CFN) e Base da MB, denotando os tipos de OM onde foram efetuadas as análises das previsões dos itens de estoque de alimentos.

A escolha dessas OM deu-se pelo fato de representarem os principais tipos de OM com peculiaridades distintas na Força, mas que realizam o fornecimento diário de refeições aos seus militares e servidores civis (SCRIVANO; COSTA; COSTA, 2020), o que demanda de suas respectivas estruturas administrativas o gerenciamento dos estoques de gêneros alimentícios (MELLO *et al.*, 2021).

A Figura 4 ilustra a distribuição dos nove Distritos Navais (DN) da MB, que representam as regiões geográficas onde as OM da MB estão distribuídas no território nacional. Em paralelo, é possível observar a capilaridade do Municionamento na Força, haja vista que o fornecimento de alimentos está atrelado às atividades administrativas de quase todas as OM da instituição.

Figura 4 – Distribuição dos DN no território nacional



Fonte: MARINHA DO BRASIL, 2021.

Nesse sentido, a Tabela 1 detalha a distribuição das quantidades de OM sediadas em terra e dos navios que possuem a estrutura do Municíamento em cada DN.

Tabela 1 – Distribuição das OM

Área	OM terra	Navios
1º DN	53	41
2º DN	4	8
3º DN	11	8
4º DN	9	9
5º DN	9	5
6º DN	1	10
7º DN	7	-
8º DN	4	1
9º DN	3	10
TOTAL	101	92

Fonte: MARINHA DO BRASIL, 2021.

Conforme evidenciado na Tabela 1, a maior parcela de OM que possui a estrutura do Municíamento está localizada na região sob a jurisdição do Comando do 1º Distrito Naval (Com1º DN), onde está situada a sede da Marinha do Brasil. Além disso, nessa região estão situados os navios que possuem maiores portes, pertencentes à Esquadra brasileira e apoiados administrativamente pelo CeIMNi.

Os resultados desta pesquisa poderão influenciar as atividades contábeis de OM distribuídas em todo o território nacional, podendo acarretar a adoção de mecanismos gerenciais

de planejamento e controle no âmbito da contabilidade da instituição, sobretudo no setor de alimentação.

2.3 Coleta de dados

Os dados utilizados na presente pesquisa foram coletados no banco de dados do sistema Quaestor, na Diretoria de Finanças de Marinha (DFM). Conforme mencionado por Santana e Corrêa (2014), a DFM é uma Organização Militar sediada na cidade do Rio de Janeiro e subordinada à Secretaria-Geral da Marinha (SGM), e tem como atribuições dirigir as atividades afetas à Contabilidade, Finanças e Economia.

Além disso, a DFM é o Órgão Central de Contabilidade e de Setorial Financeira do Comando da Marinha, sendo a referida OM a interlocutora da MB junto à Secretaria do Tesouro Nacional (STN) (SANTANA; CORRÊA, 2014).

Nesse contexto, os assuntos contábeis relacionados ao setor de alimentação da Força são normatizados pela DFM, que gerencia o sistema corporativo Quaestor, desenvolvido para o controle dos estoques de alimentos nas OM da MB (MELLO; SANTOS JUNIOR; PESSANHA, 2021).

Com isto, foram coletados no banco de dados do Quaestor o histórico de consumo de seis tipos de gêneros alimentícios que são comuns aos estoques das OM, selecionados com base na classificação dos alimentos com maiores custos no exercício de 2019. Os dados de consumo foram referentes aos seguintes itens de estoque: arroz; feijão; açúcar; peito de frango; banana e batata. Desta forma, foi possível utilizar nas análises os dados de três categorias de alimentos, quais sejam: gêneros secos; gêneros frigorificados e hortifrutigranjeiros.

Sendo assim, foram extraídos os dados mensais de consumo dos itens, em Kg, em uma OM de Ensino, uma OM Administrativa, um Hospital Naval, duas OM do CFN e uma Base da MB, durante o período de 2014 a 2019, sendo os dados do período de 2014 a 2018 utilizados para ajuste dos modelos preditivos e os dados de 2019 para comparação com as previsões obtidas, conforme sugerido por Pochiraju e Seshadri (2019) e Makridakis, Spiliotis e Assimakopoulos (2018).

Adicionalmente, foram coletados os dados de consumo de um item de estoque de alimentos de um navio da MB, que englobou o período de 2015 a 2019, período este menor do que o utilizado nas demais OM, haja vista que o processo de implantação do Quaestor nos

navios ainda se encontra em andamento (BRASIL, 2015), fato este que dificultou a obtenção de dados contínuos de consumo de alimentos neste tipo de OM. Para a análise das previsões no navio, os dados do período de 2015 a 2018 foram utilizados para o ajuste dos modelos preditivos, enquanto os dados de 2019 para a comparação com as previsões obtidas.

2.4 Tratamento dos dados

Para o tratamento dos dados coletados, utilizou-se como ferramenta computacional o *software* estatístico R (R CORE TEAM, 2021), que segundo Silva *et al.* (2017) possibilita aos pesquisadores da área de contabilidade e finanças a obtenção de resultados consistentes e robustos em pesquisas com abordagem quantitativa.

Em paralelo, Barros *et al.* (2020), Hyndman e Khandakar (2008) e Martínez *et al.* (2019) elucidam que os mecanismos do *software* R permitem o emprego da ferramenta em estudos que utilizam séries temporais e suas modelagens. De acordo com os autores, a partir do pacote *forecast*, é possível operacionalizar métodos de suavização exponencial, como o de Holt-Winters e a metodologia Box & Jenkins, executados por meio das funções *HoltWinters* e *auto.arima*, respectivamente.

Antes da execução dos processos preditivos, foram escolhidos os itens a serem analisados em tais processos. Para isto, realizou-se o levantamento dos valores dos custos de cada item cadastrado no banco de dados do Quaestor no exercício de 2019, o que possibilitou elencar os cinco itens com maiores custos nas categorias “gêneros secos”, “gêneros refrigerados” e “hortifrutigranjeiros”. Segundo Reis *et al.* (2019), este procedimento permite identificar os itens que geram maior impacto orçamentário-financeiro na gestão de estoques de uma organização. Após então, foram selecionados os itens arroz, feijão, açúcar, peito de frango, banana e batata para a extração dos dados mensais de consumo no período de 2014 a 2019. O consumo de frango foi analisado em dois tipos de OM, no caso um Hospital Naval e um navio. Cabe ressaltar que os mencionados itens são utilizados frequentemente nos cardápios das refeições das OM da Marinha do Brasil.

Conforme sugerido por Makridakis, Spiliotis e Assimakopoulos (2018); Petropoulos, Wang e Disney (2019) e Pochiraju e Seshadri (2019), foram coletados dados de consumo de cada item analisado durante um período de 60 meses para o treinamento dos modelos preditivos e 12 meses para comparação com os resultados obtidos. Os dados de consumo, em Kg,

coletados compreendeu o período de 2014 a 2019 para as OM sediadas em terra. No caso do navio, foram utilizados os dados mensais inerentes ao período de 2015 a 2019, devido à limitação encontrada para extração de séries contínuas de consumo nos navios da MB, haja vista o processo de implantação do Quaestor nas referidas OM (BRASIL, 2015).

Para a realização dos processos preditivos, foram escolhidos o método de Holt-Winters e a metodologia Box & Jenkins, também conhecida como ARIMA, a serem detalhados em seções posteriores. A escolha destes métodos fundamentou-se pelo fato de serem largamente utilizados, robustos e apresentarem bons resultados em análises preditivas de séries temporais mensais (MAKRIDAKIS; SPILLOTIS; ASSIMAKOPOULOS, 2018), além de fornecerem boa performance em estudos que envolvam controle de estoques (CHATFIELD; YAR, 1988; PETROPOULOS; WANG; DISNEY, 2019; VEIGA *et al.*, 2014).

Adicionalmente, Ghiani, Laporte e Musmanno (2004) observam que procedimentos mais complexos não garantem melhores resultados. Este fato pode ser exemplificado pelo método de Holt-Winters, que pode apresentar bons resultados quando comparado com métodos mais complexos (BRANDÃO *et al.*, 2012; MAKRIDAKIS; SPILLOTIS; ASSIMAKOPOULOS, 2018; PETROPOULOS; WANG; DISNEY, 2019).

A escolha do método de Holt-Winters e da abordagem Box & Jenkins atende a recomendação de empregar pelo menos dois métodos estatísticos no processo de previsão de séries temporais, uma vez que, esta estratégia permite realizar a comparação dos resultados obtidos, bem como proporcionar uma melhor compreensão da realidade da organização, além de minimizar as distorções entre os resultados previstos e observados (SILVA; SANTOS; COSTA, 2016).

Em cada abordagem, Holt-Winters e Box & Jenkins, respectivamente, foram adotadas duas estratégias de obtenção das previsões anuais. Em um primeiro momento foram obtidas as previsões de consumo mensais, cuja totalização para os 12 meses do ano resultou na previsão anual para o consumo do item. Já na segunda abordagem, para cada item, foi calculada a série temporal da demanda acumulada em 12 meses, i.e., a observação para o mês m corresponde ao total observado no período entre os meses m e $m-11$, assim a previsão anual corresponde à previsão para o mês de dezembro, i.e., a demanda acumulada entre janeiro e dezembro. A vantagem da segunda abordagem reside na facilidade de obtenção do intervalo de previsão anual.

A implementação computacional dos métodos de previsão contou com as funções do pacote *forecast* disponível para o *software* R (BARROS *et al.*, 2020; HYNDMAN; KHANDAKAR, 2008; SOUZA, 2020).

No Apêndice A estão dispostas as Tabelas 58, 59, 60, 61, 62, 63 e 64, contendo as séries temporais de consumo de cada item utilizado nas análises preditivas desenvolvidas nesta pesquisa. Adicionalmente, os códigos utilizados no *software* R para a execução dos processos de previsão estão expostos nos Apêndice B.

2.4.1 Métodos quantitativos para previsão de demanda

Nas duas próximas seções serão detalhados os métodos quantitativos de Holt-Winters e Box & Jenkins, com vistas à possível utilização no planejamento e controle dos estoques de alimentos da MB, sobretudo no processo de ressurgimento dos estoques, que contempla a elaboração de um ETP que contenha as previsões de consumo dos itens baseadas em métodos quantitativos, conforme disposto na nova lei de licitações e contratos (BRASIL, 2021).

2.4.1.1 Método de Holt-Winters

Dentre os métodos que viabilizam a obtenção de previsões mensais, destaca-se o método de Holt-Winters, pertencente à família dos modelos de suavização exponencial (BARROS *et al.*, 2020; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; MORETTIN; TOLOI, 2018). Segundo Chatfield e Yar (1988), este método é uma variante dos modelos de suavização exponencial e recebeu este nome em função do estudo pioneiro realizado pelos pesquisadores C. C. Holt e P. R. Winters.

Veiga *et al.* (2014) destacam que este método teve sua origem na década de 1950, com propósito de atender à uma solicitação do Escritório de Pesquisa Naval, Planejamento e Controle de Operações Industriais dos Estados Unidos. Os autores acrescentam que o objetivo era desenvolver um modelo de previsão de alta precisão e que não demandasse grandes dispêndios financeiros.

O método permite que os dados sejam modelados por componentes de média, tendência e sazonalidade, atualizados por meio da suavização exponencial, cujo efeito sazonal poderá ser aditivo ou multiplicativo (BARROS *et al.*, 2020; SILVA; SANTOS; COSTA, 2016). Portanto, trata-se de um dos métodos mais adequados para séries temporais mensais que apresentem

tendência linear e a componente de sazonalidade (BRANDÃO *et al.*, 2012; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; VEIGA *et al.*, 2014).

O método de Holt-Winters caracteriza-se por ser um procedimento de projeção robusto e de fácil aplicabilidade, que fornece uma boa performance na prática, além de não ser dispendioso (GUIMARÃES; FONSECA; RUSSO, 2015).

Outro aspecto importante do método de Holt-Winters é que este possui uma capacidade de ajustamento automático, uma propriedade importante, quando se deseja realizar atividades de controle de estoques, tendo em vista o grande número de variáveis a serem previstas (GUIMARÃES; FONSECA; RUSSO, 2015; HYNDMAN; KHANDAKAR, 2008).

O método de Holt-Winters aditivo pode ser expresso matematicamente conforme as Equações (1), (2), (3) a seguir:

$$L_t = \alpha(Z_t - S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (1)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

$$S_t = \gamma(Z_t - L_{t-1} - T_{t-1}) + (1 - \gamma)S_{t-m} \quad (3)$$

em que, α , β e γ denotam, respectivamente, os parâmetros de suavização para as componentes nível, tendência e sazonalidade, cujos valores estão delimitados ao intervalo $[0,1]$ e calibrados de forma a minimizar os quadrados dos desvios entre os valores previstos e observados (SILVA; SANTOS; COSTA, 2016; TRATAR; STRMCNIK, 2016; VEIGA *et al.*, 2014).

A previsão h passos à frente é obtida pela Equação 4, em que h indica o tamanho do período sazonal, enquanto L_t e T_t os coeficientes de nível e tendência e S_{t+h-m} o coeficiente de sazonalidade (BARROS *et al.*, 2020).

$$\hat{Z}_{t+h} = L_t + T_t h + S_{t+h-m} \quad (4)$$

As equações pertinentes ao método de Holt-Winters multiplicativo correspondem às Equações (5), (6) e (7) a seguir:

$$L_t = \alpha(Z_t/S_{t-m}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (5)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (6)$$

$$S_t = \gamma[Z_t/(L_{t-1} + T_{t-1})] + (1 - \gamma)S_{t-m} \quad (7)$$

A previsão h passos à frente, \hat{Z}_{t+h} , é obtida pela Equação 8 indicada abaixo:

$$\hat{Z}_{t+h} = (L_t + T_t h) S_{t+h-m} \quad (8)$$

Mello *et al.* (2021) destacam que nas versões aditiva e multiplicativa, α , β e γ se configuram como parâmetros delimitados ao intervalo $[0,1]$ e calibrados de forma a minimizar os quadrados dos desvios entre os valores previstos e observados. Barros *et al.* (2020) acrescentam que caso os parâmetros apresentem valores mais próximos de um, significa que os dados mais recentes da série exercem maior peso nas previsões, enquanto valores próximos de zero sugerem que os dados mais antigos da série é que exercem maior influência nos valores preditivos.

O método de Hol-Winters pode ser operacionalizado pelo *software* R, por meio da função *HoltWinters* da biblioteca *forecast* (BARROS *et al.*, 2020; HYNDMAN; KHANDAKAR, 2008).

2.4.1.2 Metodologia Box & Jenkins

Morettin e Toloí (2018) destacam que, ao se obter uma série temporal, alguns objetivos são estabelecidos para sua respectiva análise, quais sejam:

- Identificar o processo estocástico ou mecanismo que originou a série temporal observada; e
- Efetuar as previsões de valores futuros da série temporal.

Na busca pela obtenção de previsões a partir de séries temporais, Barros *et al.* (2020) e Souza e Camargo (1996) esclarecem que é necessário trazer à tona a definição do que seja um processo estocástico, i.e., um modelo que possibilita a descrição, ao longo do tempo, de uma estrutura de probabilidade de uma sequência de observações. Desta forma, um processo estocástico é uma sequência variáveis aleatória $Z = \{Z_t, t \in \mathbb{N}\}$ ordenadas no tempo, de forma que para cada $t \in \mathbb{R}$, Z_t representa uma variável aleatória.

Ao considerar que Z_t seja oriunda de um experimento capaz de ser reproduzido sob condições análogas, tem-se então em cada experimento realizado, um registro dos valores da variável aleatória Z_t ao longo do tempo, ou seja, este entendimento baseia-se na ideia de que as observações passadas possuem informações sobre o padrão de comportamento futuro (MORETTIN; TOLOI, 2018; SOUZA; CAMARGO, 1996).

Desta forma, os referidos registros, quando observados individualmente, representam uma realização do processo estocástico latente, enquanto uma amostra deste processo remete à definição de uma série temporal (GUJARATI; PORTER, 2011).

Sendo assim, uma série temporal pode ser considerada como uma realização parcial de um processo estocástico latente, portanto se configurando como uma amostra finita das observações ao longo do tempo (SOUZA; CAMARGO, 1996).

Morettin e Toloí (2018) esclarecem que um processo estocástico é determinado estatisticamente quando as funções de distribuição são conhecidas até a N -ésima ordem. Entretanto, de acordo com os autores, ocorrem algumas limitações de ordem prática, como o não conhecimento de todas as funções de distribuição até a N -ésima ordem, e o fato de se dispor de apenas uma realização do processo estocástico, que é utilizado para se inferir as características do mecanismo gerador da série. Diante disto, para que as referidas limitações sejam superadas assumem-se duas restrições, quais sejam: estacionariedade e ergodicidade (MORETTIN; TOLOI, 2018).

Barros *et al.* (2020) mencionam que, caso o processo estocástico que originou a série de observações tenha propriedades invariantes no tempo, diz-se que este é estacionário, caso contrário, é considerado não estacionário. Nesse escopo, diz-se que um processo estocástico é estacionário quando não ocorre variação de suas características ao longo do tempo, ou seja, as variáveis aleatórias Z_t e Z_{t+k} possuem distribuições idênticas de probabilidade para qualquer valor de k (BARROS *et al.*, 2019; GUJARATI; PORTER, 2011; MORETTIN; TOLOI, 2018; SCHEFFER; SOUZA; ZANINI, 2014).

Gujarati e Porter (2011) reforçam que, quando apenas uma realização do processo estocástico é suficiente para a obtenção de todas as estatísticas deste, pode-se dizer que o processo é ergódico. Os autores ainda mencionam que, todo processo ergódico é estacionário, haja vista ser impossível que uma realização de um processo não estacionário contenha todas as informações necessárias à especificação de um processo.

Na previsão de uma série temporal, as premissas de ergodicidade e estacionariedade permitem valer-se da invariância temporal do processo estocástico subjacente para inferir as

características do processo estocástico latente a partir da série temporal observada (MORETTIN; TOLOI, 2018).

Com isto, quando se estuda uma série temporal oriunda de um processo estocástico estacionário pode-se concluir que a série representa uma realização amostral que possui uma forma similar à de outras que poderiam ter sido extraídas do mesmo processo, o que possibilita a estimação das características do processo e a realização de previsões (SOUZA; CAMARGO, 1996).

Em processos estocásticos envolvendo apenas variáveis gaussianas, a condição de estacionariedade é menos restritiva (estacionariedade fraca) e pode ser expressa pela invariância do seu valor médio, $E(Z_t)$, e sua variância, $E[(Z_t - \mu)^2]$, além do fato de suas autocovariâncias, $Cov(Z_t, Z_{t+k})$, dependerem apenas do intervalo de tempo (*lag*) k entre as observações, conforme expresso nas equações abaixo:

$$E(Z_t) = E(Z_{t+k}) = \mu, \forall t \quad (9)$$

$$E[(Z_t - \mu)^2] = \sigma^2, \forall t \quad (10)$$

$$Cov(Z_t, Z_{t+k}) = Cov(Z_{t+m}, Z_{t+m+k}), \forall m \quad (11)$$

A previsão de séries temporais estacionárias pode ser realizada por meio da metodologia Box & Jenkins (VEIGA *et al.*, 2014), difundida por George Box e Gwilym Jenkins nos anos 1970 (LIMA; CASTRO; CARTAXO, 2019).

Morettin e Toloi (2018) destacam que, desde então, este método tem sido aderido de forma ampla nas análises que disponham de modelos paramétricos. A mencionada metodologia possibilita que modelos autorregressivos integrados de médias móveis sejam ajustados a um conjunto de dados, e é usualmente conhecida pela notação ARIMA (p, d, q) (*Autoregressive Integrated Moving Average*) (WERNER, 2019).

Neste método, p e q definem a ordem do modelo no que tange às componentes autorregressiva e de média móvel, respectivamente, enquanto d , denota o número de diferenciações necessárias à remoção da tendência, caso seja necessária a adoção deste procedimento (BARROS *et al.*, 2020).

Cardoso e Cruz (2016) detalham que a família ARIMA pode ser decomposta em alguns modelos mais simples, como o Autorregressivo (AR), cujo valor de q é nulo ($q=0$). De acordo com os autores, esta particularidade do ARIMA indica que em alguns pontos da série temporal, os dados apresentam fortes correlações com os valores antecessores.

Em paralelo, Lima, Castro e Cartaxo (2019), destacam que uma outra particularidade da família ARIMA é o modelo Média Móvel (MA). Segundo os autores, neste caso, o valor de p é que possui valor nulo ($p=0$), sendo a ordem do modelo expressa por q , o que leva à uma relação linear entre as componentes passadas do erro aleatório e os valores previstos da série estudada.

Para o caso em que p e q são diferentes de zero simultaneamente, tem-se o modelo Autorregressivo de Média Móvel (ARMA), o que gera a superposição dos dois métodos anteriores (AR e MA), quando da aproximação da série temporal (BARROS *et al.*, 2020).

Nesse sentido, Morettin e Toloi (2018) explicitam que o modelo ARIMA possui a sua representação geral dada pela Figura 5 a seguir:

Figura 5 – Modelo ARIMA

$$(1 - \phi_1 B - \dots - \theta_p \phi^p)(1 - B)^d y_t = (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t$$

Fonte: MORETTIN; TOLOI, 2018.

Na Figura 5, B representa o operador de defasagem, e ε_t configura o erro aleatório, que denota uma variável independente, distribuída identicamente e que possui média igual a zero e constância em sua variância (CARDOSO; CRUZ, 2016). Os coeficientes ϕ e θ denotam as componentes autorregressiva e de média móvel, respectivamente (SPERANZA; FERREIRA; COSTA, 2018).

Para os casos em que a série temporal a ser estudada venha indicar aspectos de sazonalidade, o modelo ARIMA (p,d,q) passa a ser chamado de SARIMA (p,d,q)(P,D,Q)_s (*Seasonal Autoregressive Integrated Moving Average*), tendo em vista a necessidade de análises na parte sazonal da série a ser utilizada, haja vista que esta exerce influência no processo de ajuste do modelo de previsão (CAMPOS; CLEMENTE; CORDEIRO, 2006).

Considerando a componente sazonal, Speranza, Ferreira e Costa (2018) destacam que a representação matemática que generaliza o método Box & Jenkins passa a ser expressa pela Figura 6, disposta a seguir:

Figura 6 – Modelo SARIMA

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps})(1 - B^s)^D(1 - B)^d y_t = (1 - \theta_1 B - \dots - \theta_q B^q)(1 - \Theta_1 B^s - \dots - \Theta_Q B^{Qs}) \varepsilon_t$$

Fonte: MORETTIN; TOLOI, 2018.

em que:


- p e q são, respectivamente, os graus dos polinômios das partes autorregressiva e de média móvel da componente não sazonal;
- P e Q são, respectivamente, os graus dos polinômios das partes autorregressiva e de média móvel da componente sazonal;
- d é a ordem das diferenças simples para remover a tendência da série;
- D é a ordem das diferenças sazonais para remover a sazonalidade;
- S é o período sazonal (Ex.: séries discretizadas mensalmente $S=12$);
- y_t é a série temporal estudada;
- B é o operador de defasagem;
- ε_t é o erro aleatório no instante t ;
- ϕ e θ são, respectivamente, os coeficientes das partes autorregressiva e de média móvel da componente não sazonal; e
- Φ e Θ são, respectivamente, os coeficientes das partes autorregressiva e de média móvel da componente sazonal.

Barros *et al.* (2020) salientam que para o emprego deste método em estudos preditivos, o processo estocástico a ser estudado deverá atender aos requisitos de estacionariedade.

De uma forma geral, a maioria das séries utilizadas em estudos econômicos e financeiros apresenta em suas características a não estacionariedade, o que conduz em alguns casos, à necessidade de transformá-las em estacionárias por meio do processo de diferenciação (SOUZA, 2020). Quando o objetivo é tornar a variância constante a aplicação de uma transformação Box-Cox pode ser adotada (BRANDÃO *et al.*, 2012).

Na Figura 7, é possível observar a exemplificação gráfica de uma série temporal com características de estacionariedade, tendo em vista a amplitude da variância apresentar-se constante ao longo do tempo, bem como os indícios de ausência de tendências (MORETTIN; TOLOI, 2018).

Figura 7 – Série Temporal estacionária

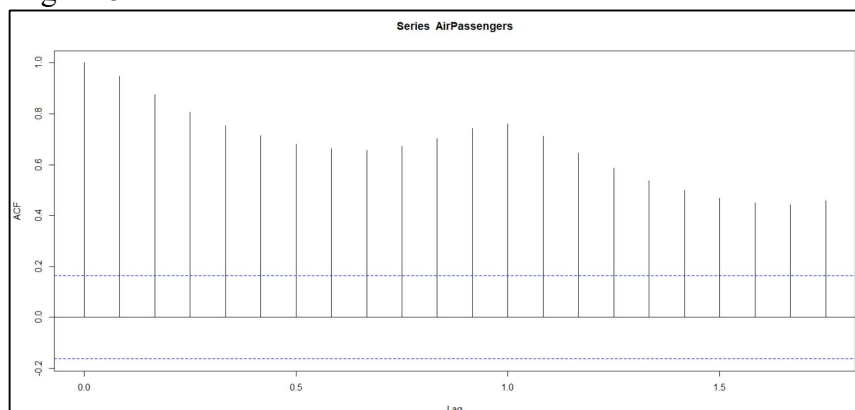


Fonte: MORETTIN; TOLOI, 2018.

Caso em uma das partes da série (componente regular ou sazonal), ou em ambas, sejam apresentados indícios de que a série é não estacionária, baseado na análise do comportamento do gráfico da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP), deverá então ser efetuado o processo de diferenciação, de forma que a tendência seja removida antes do emprego da metodologia Box & Jenkins (MORETTIN; TOLOI, 2018).

Caso o gráfico da FAC exponha um lento decaimento das correlações ao longo do tempo, significa que este comportamento sugere tratar-se de uma série não estacionária e que como consequência, deverá ser tomada a diferença para adequá-la ao processo de previsão (BARROS *et al.*, 2020). Na Figura 8 é possível verificar um exemplo do comportamento que indica a necessidade de realização da diferenciação, devido ao comportamento da FAC, que apresenta um decaimento lento ao longo do tempo.

Figura 8 – FAC com decaimento lento



Fonte: BARROS *et al.*, 2020.

Após a constatação da não estacionariedade da série e realizado o procedimento de diferenciação, para remoção das tendências e promoção da estabilidade na variância, é que a série poderá ser empregada no ajuste do modelo preditivo ARIMA (CARDOSO; CRUZ, 2016).

Almeida (2018) e Speranza, Ferreira e Costa (2018) trazem à tona que para validação dos requisitos de estacionariedade, em geral, é comum a utilização de testes de hipóteses, como o Dickey-Fuller (ADF), para a constatação de existência de ou não de raiz unitária. Barros *et al.* (2020) ainda mencionam o emprego de outros testes usuais para esta finalidade, como o Teste de Kwiatkowski, Philips, Schmidt e Shin (KPSS).

Adicionalmente, cabe mencionar que o *default* da função *auto.arima* do pacote *forecast* do *software* R, desenvolvido para estudos preditivos, utiliza os testes estatísticos ADF e KPSS para o fornecimento da sugestão dos modelos SARIMA $(p,d,q)(P,D,Q)$ nos diferentes tipos de estudos que envolvem previsões de séries temporais (HYNDMAN; KHANDAKAR, 2008).

Complementarmente, Lima, Castro e Cartaxo (2019) revelam que os valores de p e q , que remetem às ordens dos termos autorregressivos e de média móvel, respectivamente, podem ser obtidos a partir da análise dos gráficos da FAC e FACP, após serem efetuadas as d diferenciações, caso ocorram. Os autores ainda reforçam que esta análise gráfica contribui para a identificação do modelo que melhor descreva a série temporal.

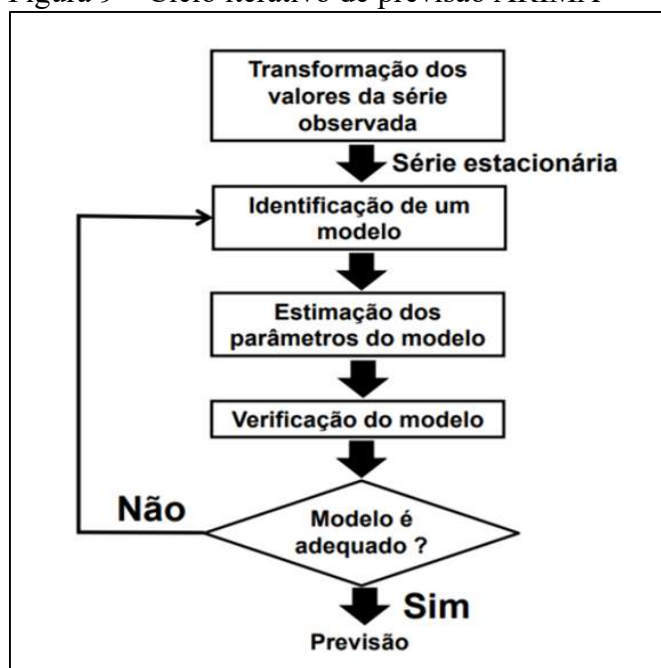
Após a transformação da série original em uma série estacionária, o próximo passo consiste na execução de um ciclo iterativo que visa obter os valores estimados com base na série empregada no estudo (BARROS *et al.*, 2020).

Para a construção deste modelo preditivo, Morettin e Tolo (2018) e Speranza, Ferreira e Costa (2018) destacam a estratégia de utilização deste ciclo iterativo, que se vale dos próprios dados da série temporal para selecionar a estrutura do modelo. Conforme destacado pelos autores, esta estratégia dispõe dos seguintes estágios: *identificação, estimação, verificação e previsão*.

Complementarmente, Gujarati e Porter (2011) resumem o mencionado ciclo como o processo que visa descobrir os valores de p , d , q , P , D e Q (identificação), bem como as respectivas estimações dos parâmetros dos termos autorregressivo e de média móvel (estimação). Em seguida, os autores destacam a checagem do diagnóstico (verificação), verificando se os ruídos do modelo são ruídos brancos e, por fim, a obtenção das previsões (previsão).

Nesse sentido, a Figura 9 ilustra a execução das fases do ciclo iterativo, até o estágio em que se obtém a previsão:

Figura 9 – Ciclo iterativo de previsão ARIMA



Fonte: Adaptada de MORETTIN; TOLOI, 2018.

A fase de *identificação* se traduz no processo de definição dos valores de p , q , P , e Q do modelo SARIMA (CAMPOS; CLEMENTE; CORDEIRO, 2006). Nesta fase, a observação e análise da FAC e da FACP, tornam-se essenciais ao estabelecimento dos valores que definem a ordem do modelo (SPERANZA; FERREIRA; COSTA, 2018).

Porém, como mencionado anteriormente, atualmente existem recursos computacionais, como a função *auto.arima* do pacote *forecast* do *software* R, que indica de forma automatizada as sugestões de valores para os parâmetros do modelo (LIMA; CASTRO; CARTAXO, 2019; SOUZA, 2020; SPERANZA; FERREIRA; COSTA, 2018).


Entretanto, embora se disponha das ferramentas computacionais, não se pode descartar a análise da FAC e da FACP no processo de escolha do modelo que minimize os critérios de informação, tendo em vista que a referida análise permitirá confirmar as sugestões de valores fornecidas pelas função *auto.arima* do pacote *forecast* do R (MORETTIN; TOLOI, 2018).

Além disso, ainda na fase de *identificação*, constata-se por meio da análise da FAC e da FACP, a necessidade ou não do emprego do processo de diferenciação para a remoção de tendência, uma vez que estas são utilizadas para analisar o comportamento futuro da série com base em observações passadas (MARTIN *et al.*, 2016).

A análise gráfica da FAC e FACP, além de auxiliarem na identificação dos valores das ordens dos termos autorregressivos (p e P) e de médias móveis (q e Q) (CARDOSO; CRUZ, 2016), permite verificar indícios de sazonalidade quando observadas a presença de picos e vales

periódicos no gráfico da FAC (LIMA; CASTRO; CARTAXO, 2019), conforme exemplificado na Figura 10 abaixo:

Figura 10 - FAC com presença de picos e vales



Fonte: LIMA; CASTRO; CARTAXO, 2019.

Embora a FAC e FACP possuam teoricamente comportamentos que descrevam características úteis ao processo de ajuste do modelo, estas, por serem estimadas, podem apresentar em alguns casos, comportamentos de difícil interpretação (BARROS *et al.*, 2020).

No entanto, reforça-se que a busca deve ser sempre que possível pela obtenção de modelos parcimoniosos, tendo em vista que estes apresentam melhor qualidade de produção das previsões do que os modelos sobreparametrizados (GUJARATI; PORTER, 2011).

Nesse sentido, menciona-se a existência de vários critérios de seleção de modelos que permitem encontrar um ponto de equilíbrio entre a redução na soma do quadrado dos resíduos e a parcimônia do modelo. Um dos critérios mais utilizados é o AIC (*Akaike Information Criterion*), que viabiliza a comparação entre as variâncias dos erros dos modelos (MORETTIN; TOLOI, 2018). Neste caso, quanto menor for o valor do AIC, menor também será o ruído, e por conseguinte, melhor o modelo (HYNDMAN; KHANDAKAR, 2008).

Posteriormente à fase de *identificação* provisória do modelo para a série temporal, são realizados os procedimentos de *estimação* de seus parâmetros (BARROS *et al.*, 2020). Hyndman e Khandakar (2008) e Souza (2020) ressaltam que para isto, são testados os valores possíveis dos modelos SARIMA idealizados com base na análise gráfica das FAC e FACP ou valores propostos pela função *auto.arima*. Ainda de acordo com os autores, para a operacionalização deste procedimento, as funções *Arima* e *auto.arima* do pacote *forecast* do R dispõem do método da Máxima Verossimilhança (*Maximum Likelihood*) em seu *default*.

Em seguida, é necessária a realização da *verificação* ou *diagnóstico* do modelo, ou seja, é checado se o modelo representa adequadamente os dados (BARROS *et al.*, 2020; MORETTIN; TOLOI, 2018; SOUZA, 2020). Conforme os autores, após a definição da

estrutura mais adequada e estimados os parâmetros do modelo proposto, a fase de *verificação* consiste em analisar algumas características dos resíduos, que precisam atender alguns padrões específicos para que o modelo seja válido, e por conseguinte sejam obtidas previsões através dele.

Caso ocorra alguma inadequação com o modelo, sugere-se a utilização da técnica de *superajustamento*, que visa estimar um modelo com parâmetros extras e a posterior verificação se estes são significativos, bem como se estas inclusões reduzem significativamente a variância residual (HYNDMAN; KHANDAKAR, 2008).

No que tange a análise dos resíduos, as características que precisam ser cheçadas englobam a verificação da ausência de autocorrelação linear; ausência de heterocedasticidade condicional; e por fim, da normalidade dos resíduos (MORETTIN; TOLOI, 2018).

Neste processo, alguns testes difundidos são empregados para a análise dos resíduos. O teste de Shapiro-Wilk permite a verificação da condição de normalidade dos resíduos, enquanto o teste Ljung-Box (ou teste Portmanteau) viabiliza a checagem de existência de estruturas de autocorrelação entre os resíduos, utilizando adicionalmente a análise da FAC e FACP dos resíduos (SPERANZA; FERREIRA; COSTA, 2018; BARROS *et al.*, 2020).

Executadas as fases anteriores, utiliza-se o modelo identificado e estimado para a realização e obtenção das previsões. Nesta etapa o objetivo principal é obter os valores estimados e analisar as métricas de desempenho do modelo, que permitirão confirmar a qualidade das previsões (MORETTIN; TOLOI, 2018).

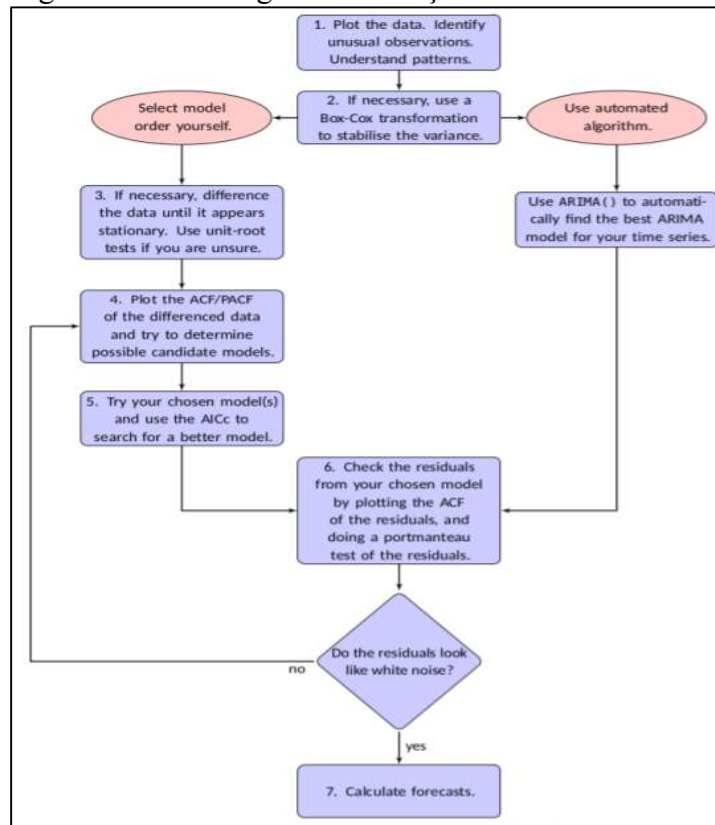
Cabe destacar que, após a execução das fases do ciclo, caso o modelo venha a se apresentar inadequado, é necessário retornar à fase de identificação (GUJARATI; PORTER, 2011). Neste caso, é comum que os analistas identifiquem mais de um tipo de modelo, e estimem e verifiquem o que melhor se ajustou ao caso em estudo (HYNDMAN; KHANDAKAR, 2008).

Com isto, uma forma de distinguir o modelo mais adequado para a execução das previsões é utilizar de medidas de desempenho como a Raiz do Erro Quadrático Médio de previsão (RMSE) (*Root Mean Square Error*) e o Valor Médio do Erro Percentual (MAPE) (*Mean Absolute Percentage Error*) (VEIGA *et al.*, 2014).

Releva mencionar, que os modelos devem ser parcimoniosos, ou seja, conter um número reduzido de parâmetros. O método ARIMA proporciona previsões bastante precisas quando comparadas a outros métodos de previsão (MAKRIDAKIS; SPILIOTIS; ASSIMAKOPOULOS, 2018).

Entretanto, embora existam ferramentas de Tecnologia da Informação (TI) que viabilizem a obtenção das previsões, neste método são necessárias análises preliminares por parte dos pesquisadores antes da utilização dos recursos computacionais nos processos de ajustes dos modelos preditivos (SPERANZA; FERREIRA; COSTA, 2018). A Figura 11 apresenta as possíveis estratégias para a obtenção de um modelo preditivo da família ARIMA através do *software* R.

Figura 11 – Estratégias de obtenção do modelo ARIMA



Fonte: Adaptada de HYNDMAN; KHANDAKAR, 2008.

Hyndman e Khandakar (2008) mencionam que inicialmente devem ser realizados alguns procedimentos preliminares, como gerar o gráfico da série, observar se há a existência de dados incomuns e entender os padrões da série a ser analisada. Em seguida, caso seja necessário, deverá ser realizada uma transformação Box-Cox para estabilizar a variância dos dados.

Após a execução dos procedimentos preliminares, poderá ser efetuada a escolha da estratégia a ser adotada para a obtenção do modelo. Caso seja adotada a estratégia elencada pela ramificação da esquerda do fluxograma contido na Figura 11, o analista deverá selecionar a ordem do modelo, diferenciando a série até que se torne estacionária, caso necessário. Poderá ainda ser realizado um teste de raiz unitária para confirmar a estacionariedade da série

(SPERANZA; FERREIRA; COSTA, 2018). Em seguida o exame da FAC e FACP torna-se necessário para identificação da possível ordem do modelo a ser escolhido, além da utilização do AIC como um dos critérios de escolha do modelo (MAKRIDAKIS; SPILLOTIS; ASSIMAKOPOULOS, 2018).

Posteriormente, deve ser realizada a análise dos resíduos, com a devida verificação da FAC dos resíduos e a realização do teste de Portmanteau (ou Ljung-Box) dos resíduos. Caso os resíduos não apresentem características de um ruído branco, deve-se buscar um outro modelo. Quando os resíduos apresentarem características de um ruído branco, poderão ser geradas as previsões a partir do modelo obtido (BARROS *et al.*, 2020; HYNDMAN; KHANDAKAR, 2008).

A segunda possibilidade de estratégia ser seguida está disposta na ramificação da direita do fluxograma contido na Figura 11, em que é utilizada a automação da função *Arima* do *software* R, que em seu *default* dispõe dos procedimentos de verificação da estacionariedade da série, a partir dos testes ADF e KPSS, e gera uma sugestão de modelo ARIMA para o cálculo das previsões (SPERANZA; FERREIRA; COSTA, 2018). Sequencialmente, o analista deverá realizar a análise dos resíduos, assim como descrito na primeira possibilidade de estratégia de obtenção do modelo (ramificação da esquerda).

Nesta pesquisa, foi empregada a estratégia que dispõe de mecanismos automatizados no *software* R para a obtenção da ordem dos modelos, no caso a função *auto.arima*. Através desta ferramenta obteve-se as previsões mensais para o ano de 2019, bem como o valor de previsão para o acumulado de 12 meses. Petropoulos, Wang e Disney (2019) destacam em sua pesquisa que a função *auto.arima* é capaz de proporcionar bons resultados preditivos para as atividades de controle de estoque.

2.4.1.3 Combinação de previsões

Como parte do processo de tratamento dos dados, após a obtenção e análise individualizada das previsões de consumo dos gêneros alimentícios com base no método de Holt-Winters e na metodologia Box & Jenkins, foram adotados dois procedimentos de combinações de previsões. Com isto, foi possível analisar os MAPE e os desvios anuais das previsões combinadas frente aos resultados obtidos pelos métodos de Holt-Winters e ARIMA.

Werner (2019) menciona que o método de combinação de previsões foi idealizado pelos pesquisadores Bates e Granger em 1969 visando trazer benefícios de acurácia em estudos preditivos. O autor ainda acrescenta que as previsões combinadas são operacionalizadas por meio de transformações matemáticas das previsões individuais obtidas através de métodos clássicos, e busca o fornecimento de uma previsão com melhor precisão.

Nowotarski e Weron (2016) destacam que a combinação traz como principal vantagem o fornecimento de mais uma opção de modelo, de forma que seja selecionado pelos analistas aquele que possuir um melhor ajuste aos dados da série temporal. Costantini e Pappalardo (2010) enfatizam que a combinação linear das previsões, em muitos casos, fornece um resultado mais robusto do que os fornecidos pelos métodos individuais.

Diante de uma maior adesão ao referido método em estudos que envolvem previsões, foi possível a obtenção de evidências empíricas que demonstraram que a combinação linear de previsões de diferentes modelos se configura em uma estratégia de proteção aos riscos envolvidos nos processos preditivos (WEISS; RAVIV; ROETZER, 2018). Entretanto, nem sempre a combinação fornece as melhores previsões quando comparadas aos resultados obtidos pelos métodos individuais (NOWOTARSKI; WERON, 2016).

Desta forma, esta pesquisa adotou dois métodos de combinação de previsões. O primeiro se refere ao método de combinação baseado na Regressão Linear por Mínimos Quadrados Ordinários (OLS), cuja formulação geral é expressa pela Equação 12.

$$y = \alpha + w_1 f_1 + \dots + w_p f_p + \varepsilon \quad (12)$$

em que a previsão combinada (y) é dada pela soma ponderada das previsões f_i , $\forall i=1,P$, oriundas de P modelos de previsão, ε é o termo aleatório não observável presente em qualquer equação de regressão linear, enquanto o intercepto α e os coeficientes (pesos) w são os parâmetros, estimados por mínimos quadrados ordinários a partir dos valores observados de y e das respectivas previsões no período histórico (*in sample*).

Matematicamente, as estimativas do intercepto α e dos coeficientes w são obtidas por meio da minimização da soma dos quadrados dos erros, i.e., a solução do seguinte problema de programação quadrática (Equação 13), no qual y_t e $f_{i,t}$, $\forall i=1,P$ denotam os valores observados e previstos ao longo dos T meses do período histórico:

$$\underset{\alpha, w}{Min} \sum_{t=1}^T (y_t - \alpha - w_1 f_{1,t} - \dots - w_p f_{p,t})^2 \quad (13)$$

A combinação por meio da regressão linear não impõe restrições aos pesos da combinação, ou seja, não totalizam um e podem ser expressos por valores negativos (WEISS; RAVIV; ROETZER, 2018).

A previsão combinada h passos à frente é dada pela Equação 14:

$$\widehat{y}_{t+h} = \widehat{\alpha} + \widehat{w}_1 f_{1,t+h} + \cdots + \widehat{w}_p f_{p,t+h} \quad (14)$$

em que $\widehat{\alpha}$ e $\widehat{w}_i \forall i=1,P$ denotam as estimativas obtidas por mínimos quadrados

O segundo método de combinação utilizado é a combinação convexa das previsões, i.e., a soma ponderada das previsões com pesos que somam um valor unitário, conforme representado pelas Equações 15 e 16.

$$y = w_1 f_1 + \cdots + w_p f_p \quad (15)$$

tal que

$$w_1 + \cdots + w_p = 1 \quad (16)$$

Neste caso, as estimativas dos pesos w são obtidas por meio da minimização da soma dos quadrados dos erros, i.e., a solução do seguinte problema de programação quadrática com restrição, expresso pela Equação 17:

$$\begin{array}{ll} \text{Min} & \sum_{t=1}^T (y_t - w_1 f_{1,t} - \cdots - w_p f_{p,t})^2 \\ \text{s. a.} & w_1 + \cdots + w_p = 1 \end{array} \quad (17)$$

A previsão combinada h passos à frente é dada pela Equação 18:

$$\widehat{y}_{t+h} = \widehat{w}_1 f_{1,t+h} + \cdots + \widehat{w}_p f_{p,t+h} \quad (18)$$

Sendo assim, para a operacionalização da combinação por regressão linear utilizou-se o pacote *ForecastComb*, enquanto na combinação convexa utilizou-se o pacote *opera*, ambos disponíveis para o *software* R. Os pacotes viabilizaram a obtenção das previsões combinadas

de consumo de alimentos para o exercício de 2019 nas OM da MB analisadas, bem como a comparação da acurácia e do desvio anual de cada um dos modelos utilizados.

Por fim, é importante destacar que a qualidade da previsão resultante da combinação de previsões individuais depende da qualidade dos blocos de construção envolvidos (NOWOTARSKI; WERON, 2016). Se um determinado método supera o outro com certa constância, pode ser que a combinação não seja vantajosa.

2.4.1.4 Medidas de Acurácia

Após a realização do ajuste do modelo preditivo e a obtenção das previsões, é necessária a verificação do modelo que melhor se adequa para o emprego do processo de previsão analisado (GUIMARÃES; FONSECA; RUSSO, 2015). Para isto, são utilizadas algumas medidas de acurácia que indicam os desvios entre os valores previstos e os valores observados, em que N denota o número de observações que são utilizadas no ajuste da curva dos dados observados.

Para isto, podem ser empregadas as medidas MAPE (Erro Percentual Absoluto Médio), MAD (Erro Absoluto Médio) ou RMSE (Raiz do Erro Quadrático Médio), e quanto menores os seus valores, melhor é a previsão (JACOB JÚNIOR *et al.*, 2018; MAKRIDAKIS; SPILOTIS; ASSIMAKOPOULOS, 2018; VEIGA *et al.*, 2014), conforme indicados nas Equações 19, 20 e 21.

$$MAPE = \sum_{t=1}^N \frac{|Z_t - \hat{Z}_t|/Z_t}{N} \times 100\% \quad (19)$$

$$MAD = \sum_{t=1}^N \frac{|Z_t - \hat{Z}_t|}{N} \quad (20)$$

$$RMSE = \sqrt{\sum_{t=1}^N \frac{(Z_t - \hat{Z}_t)^2}{N}} \quad (21)$$

em que, Z_t e \hat{Z}_t denotam, respectivamente, os valores observados e previstos em um período t .

2.5 Delimitação da pesquisa

Para esta pesquisa foram utilizadas duas abordagens para a realização dos processos de previsão de demanda, Holt-Winters e Box & Jenkins, sendo que em cada abordagem foram empregados dois mecanismos diferentes para a obtenção das previsões, totalizando ao final da pesquisa em quatro previsões para cada série temporal de consumo de gêneros alimentícios analisada, e um total de 28 previsões ao final do estudo.

Após a obtenção das previsões operacionalizadas pelo método de Holt-Winters e metodologia Box & Jenkins, efetuou-se a combinação das previsões com a utilização do método de combinação de previsão baseado na Regressão Linear por Mínimos Quadrados Ordinários (OLS) e do método de combinação convexa.

Adicionalmente, foram analisadas previsões de itens de estoque de alimentos de seis tipos de OM da MB (Ensino, Administrativa, Hospital, Navio, Fuzileiros Navais e Base), nas quais foram utilizados dados de consumo do período de 2014 a 2019, com a exceção da série oriunda do navio, que abarcou o período de 2015 a 2019 devido às limitações mencionadas anteriormente.

Foram utilizados seis tipos de gêneros alimentícios para a análise da previsão do consumo, escolhidos com base na classificação dos itens com maiores custos no exercício de 2019, e subdivididos pelas categorias: “gêneros secos”; “gêneros refrigerados” e “hortifrutigranjeiros”. Desta forma, foram selecionados os seguintes itens: arroz; feijão e açúcar (gêneros secos); frango (gênero refrigerado); batata e banana (hortifrutigranjeiros).

Os resultados encontrados neste estudo limitam-se às OM da MB analisadas, não sendo possível generalizar os achados da pesquisa para outras organizações. Além disso, as possíveis contribuições oriundas desta pesquisa remetem-se ao Municíamento da Força, não abarcando assim outros tipos de estoque gerenciados pela MB.

3 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Este capítulo dispõe dos resultados da presente pesquisa, obtidos com a utilização dos dados de consumo de seis tipos de gêneros alimentícios em seis tipos de OM da MB. A partir das séries temporais de consumo dos mencionados itens, foi possível efetuar a execução e a análise de 28 processos de previsão de demanda de gêneros alimentícios nas OM, com base no método de Holt-Winters e na metodologia Box & Jenkins. Os processos foram executados com objetivo de avaliar as contribuições que estes podem trazer aos aspectos de planejamento e controle do Município da Força.

3.1 Alimentos com maiores custos em 2019

Inicialmente foi realizada a classificação dos itens de estoque de alimentos da Marinha do Brasil que apresentaram os maiores custos em 2019, referentes aos consumos nos refeitórios das OM da Força. Desta forma foram geradas três tabelas com os cinco itens com maiores custos, integrantes dos grupos classificados como gêneros secos, gêneros refrigerados e hortifrutigranjeiros. Segundo Reis *et al.* (2019) este procedimento permite identificar os itens que geram maior impacto orçamentário-financeiro em uma organização em caso da má administração dos estoques.

A Tabela 2 dispõe dos cinco itens com maiores custos dentre os gêneros secos. Neste grupo incluem-se os grãos utilizados na elaboração dos cardápios dos almoços e jantares das OM.

Tabela 2 – Gêneros secos com maiores custos em 2019

Item	Custo (R\$)
Feijão preto	869.559,80
Arroz branco	784.422,00
Pão de forma	474.788,90
Açúcar	275.234,33
Farinha de trigo	237.576,00

Fonte: O autor, 2021.

Dentre os gêneros secos com maiores custos cabe destaque para os itens arroz e feijão, haja vista serem utilizados diariamente nos cardápios de todos os tipos de OM da MB. A Tabela 3 a seguir apresenta os cinco itens frigorificados com maiores custos no exercício de 2019.

Tabela 3 – Gêneros frigorificados com maiores custos em 2019

Item	Custo (R\$)
Frango	5.070.296,00
Alcatra bovina	2.988.946,00
Linguiça	2.646.947,00
Filé de cação	2.350.170,00
Costela bovina	2.057.544,00

Fonte: O autor, 2021.

Dentre os itens frigorificados destaca-se a presença do item “peito de frango” como o que apontou o maior custo. Este item é comumente utilizado nos cardápios das OM, além de apresentar preços de mercado melhores do que os de carnes vermelhas. A Tabela 4 dispõe dos cinco itens de hortifrutis com maiores custos em 2019.

Tabela 4 – Hortifrutigranjeiros com maiores custos em 2019

Item	Custo (R\$)
Batata	1.431.340,82
Tomate	1.309.000,80
Banana	1.143.190,00
Alho	993.031,90
Melão	847.829,40

Fonte: O autor, 2021.

Garcia *et al.* (2006) destacam ser prudente a classificação dos itens de estoque mais relevantes no âmbito de uma instituição, uma vez que quanto maior o estoque, maior também será a complexidade de seu gerenciamento. Adicionalmente, Santos e Oliveira (2016) mencionam que a classificação dos itens viabiliza uma qualificação da materialidade e o grau de prioridade de cada item que compõe o estoque de uma instituição.

Com isto, após o levantamento dos dados dos gêneros alimentícios com maiores custos em 2019, coletados no sistema Quaestor, utilizou-se alguns destes itens para a análise da previsão de demanda em seis tipos de Organizações Militares. Cabe destacar que, conforme


Machado e Holanda (2010), os novos padrões contábeis para apuração do custo do item de estoque é mensurado após o seu devido consumo, ou seja, a partir das saídas dos estoques.

3.2 Análise da previsão de consumo de arroz em uma OM de Ensino

Inicialmente, foram obtidos no banco de dados do sistema Quaestor, na Diretoria de Finanças de Marinha, os dados de consumo de arroz branco tipo I de uma OM de Ensino da Força, durante o período de 2014 a 2019. Na sequência, estes dados foram importados para o ambiente do *software* R, de forma que fosse possível iniciar o processo de previsão de demanda do referido item, 12 passos à frente, ou seja, para o ano de 2019, utilizando-se o período de 2014 a 2018 para ajuste do modelo preditivo.

Ao carregar os dados de consumo do item para o ambiente do *software* R, foi gerado o gráfico da série temporal inerente ao consumo de arroz no período de 2014 a 2018, conforme pode ser visualizado na Figura 12.

Figura 12 – Série temporal de consumo de arroz - 2014 a 2018



Fonte: O autor, 2021.

Visualmente a série temporal de consumo de arroz na OM de Ensino não expõe uma tendência nítida, embora fique evidente a presença da componente sazonal, que, conforme Pellegrini e Fogliatto (2001), é comumente encontrada em séries que representem demandas ao longo de um determinado período.


Além disso, a Figura 12 indica a presença de uma sazonalidade aditiva, tendo em vista a constância da amplitude dos valores mensais ao longo dos anos expostos na série, o que

possibilita a aplicação do método aditivo de Holt-Winters no primeiro processo preditivo a ser realizado.

A decomposição da série em suas componentes não observáveis, i.e., tendência, sazonalidade e irregular, possibilita a realização de uma análise exploratória mais detalhada a respeito do consumo de arroz na OM em questão.

A série foi decomposta por meio da funcionalidade *plot(decompose(série))* do software R, conforme ilustrado na Figura 13.

Figura 13 – Decomposição da série temporal do consumo de arroz



Fonte: O autor, 2021.

Nesse sentido, a Figura 13 evidencia a presença de uma tendência decrescente, o que sinaliza aos gestores da OM, um movimento de redução no consumo de arroz naquela OM ao longo dos últimos anos.

Este comportamento pode sugerir aos setores responsáveis pelo planejamento das compras e de gestão do estoque de alimentos, que a elaboração dos processos licitatórios e aquisições deste item não devam atingir patamares acima dos registrados nos últimos anos.

Caso haja previsão de eventos excepcionais que demandem maior consumo do item no exercício subsequente, deverá ser levado em consideração quando da realização do referido planejamento.

Já a componente sazonal revela a redução do consumo de arroz nos meses de julho e dezembro, períodos nos quais os alunos, professores e considerável parte da tripulação encontram-se em férias.

3.2.1 Previsão de consumo de arroz baseada no método de Holt-Winters

Após a análise exploratória dos dados do processo de previsão de consumo de arroz em uma OM de Ensino da MB, bem como a identificação das características da série temporal em estudo, foi iniciado o ajuste do modelo preditivo baseado no método aditivo de Holt-Winters por meio da função *HoltWinters* do *software* R. As constantes de alisamento ou parâmetros de suavização resultantes são apresentadas na Tabela 5.

Tabela 5 – Parâmetros de suavização - arroz

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

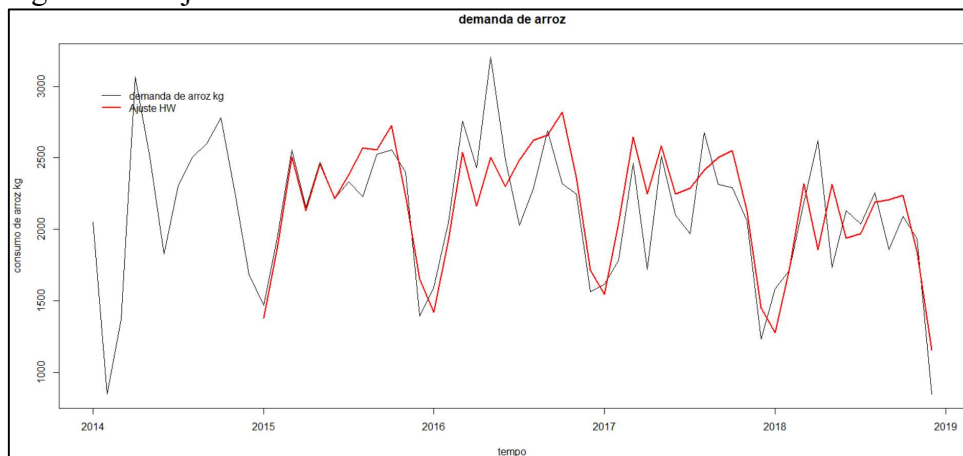
Fonte: O autor, 2021.

Após a obtenção dos parâmetros de suavização, observou-se que os coeficientes α e β apresentaram valores mais próximos à zero, o que indica que o modelo considera os dados mais antigos da série temporal com pesos maiores nas equações de nível e tendência.

Adicionalmente, o coeficiente γ , atrelado à componente sazonal, também apresentou valor próximo à zero, implicando em um peso maior para os dados mais antigos no ajuste do modelo preditivo.

A seguir, na Figura 14 apresenta-se a série temporal do consumo de arroz (em preto) e as estimativas mensais (em vermelho) resultantes do ajuste do modelo de Holt-Winters com a utilização dos dados do período de 2014 a 2018.

Figura 14 – Ajuste sazonal do consumo de arroz



Fonte: O autor, 2021.

Após a realização do ajuste do modelo, foi possível então obter previsões até 12 passos à frente, referentes ao consumo de arroz, mês a mês, para o ano de 2019 em uma OM de Ensino da MB.

Para tal, foi utilizada a função *forecast* do pacote *forecast* do R, de forma que fosse viabilizada a obtenção das previsões de demanda do arroz para o ano de 2019, apresentadas na Tabela 6, juntamente com os valores observados. Na parte inferior da Tabela 6 destacam-se os valores totais anuais do consumo de arroz para 2019, com um desvio relativo da ordem de 5,36% entre o consumo anual observado e o consumo anual previsto.

Tabela 6 – Previsão de consumo para 2019
- arroz – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	1.380	1.049,35	23,96%
Fev	1.570	1.425,29	9,22%
Mar	1.650	2.008,84	21,75%
Abr	1.620	1.670,85	3,14%
Mai	1.962	1.897,83	3,27%
Jun	1.648	1.643,23	0,29%
Jul	1.809	1.641,69	9,25%
Ago	2.070	1.850,02	10,63%
Set	1.981	1.799,32	9,17%
Out	1.941	1.865,70	3,88%
Nov	1.663	1.507,45	9,35%
Dez	905	756,08	16,46%
TOTAL	20.199	19.115,65	5,36%

Fonte: O autor, 2021.

Adicionalmente, na Tabela 7, apresentam-se as métricas MAPE, MAD e RMSE referentes aos valores mensais.


Tabela 7 – Métricas de desempenho		
MAPE	MAD	RMSE
10,03%	158,56	188,68

Fonte: O autor, 2021.

Numa perspectiva anual, verificou-se que o montante total de consumo previsto, aproximou-se em 94,64% do total efetivamente consumido. Adicionalmente, na Figura 15 tem-se a visualização das previsões mensais (linha em azul) na sequência dos valores observados e

acompanhadas dos intervalos de previsão com 95% de confiança, que indicam as magnitudes das incertezas.

Figura 15 – Previsão de consumo para 2019 - arroz - HW



Fonte: O autor, 2021.

A previsão do consumo anual atende ao contido na Instrução Normativa nº 40/2020 do Ministério da Economia (ME, 2020), que versa sobre a elaboração do Estudo Técnico Preliminar (ETP), e que prevê a utilização de métodos quantitativos para estimar as quantidades de itens de estoque a serem adquiridas por órgãos públicos federais com base no histórico de consumo dos itens nas instituições. Contudo, visando a obtenção do intervalo de confiança associado à previsão anual, pode-se adotar um procedimento alternativo que consiste em calcular a previsão do consumo acumulado nos últimos 12 meses para dezembro de 2019 (previsão 12 passos à frente), a partir da série mensal do consumo acumulado de 12 meses.

A aplicação do método de Holt-Winters na série de consumo mensal acumulado de 12 meses produziu a previsão de consumo anual disposto na Tabela 8.

Tabela 8 – Previsão acumulada para 2019 – arroz – HW

Observado	Previsão	Limite Inferior	Limite Superior	Desvio Relativo
20.199	21.568,93	18.978,97	24.158,90	6,78%

Fonte: O autor, 2021.

Conforme visualizado na Tabela 8, neste caso a previsão pontual obtida pelo procedimento alternativo apresentou um desvio relativo ligeiramente maior do que o somatório das previsões mensais, obtido anteriormente. Entretanto, a previsão anual resultante da soma das previsões mensais (19.115,65 Kg) é inferior ao consumo de arroz em 2019 (20.199 Kg),


enquanto a previsão dada pelo acumulado de 12 meses em dezembro (21.568,93 Kg) cobre com folga a demanda anual. Tais resultados demonstram ser prudente a inclusão de uma margem de segurança na previsão a ser considerada na elaboração do ETP das OM. Vale destacar que a previsão anual é uma solução de compromisso entre dois objetivos conflitantes: a mitigação dos aditivos contratuais para cobrir falhas de abastecimento e a mitigação dos custos de armazenagem das sobras.

A previsão do acumulado de 12 meses para dezembro de 2019 vem acompanhada de um intervalo de confiança que fornece uma medida do grau de incerteza da previsão anual. O intervalo de confiança e o contraste entre as previsões anuais nas Tabelas 6 e 8 fornecem subsídios para a definição de uma margem de segurança da previsão.

3.2.2 Previsão de consumo de arroz baseada na metodologia Box & Jenkins

A seguir, a FAC e a FACP da série do consumo mensal de arroz são apresentadas nas Figuras 16 e 17, respectivamente.

Figura 16 – FAC da série de consumo de arroz




Fonte: O autor, 2021.

O decaimento exponencial observado no gráfico da FAC (Figura 16) indica que não há necessidade de diferenciar a série temporal para remoção de tendência. Além disso, observa-se um pico no *lag* 1,0 que corresponde a 12 meses e outro pico próximo ao *lag* 2,0 que corresponde a 24 meses, indicando a presença de sazonalidade, e como consequência, a presença da componente autorregressiva na parte sazonal de um modelo SARIMA. A identificação da

ordem P da componente autorregressiva sazonal é realizada por meio da inspeção da FACP na Figura 17.

Figura 17 – FACP da série de consumo de arroz



Fonte: O autor, 2021.

A FACP na Figura 17 exibe uma autocorrelação parcial significativa em $lag\ 1,0$, sugerindo um modelo que detenha uma componente autorregressiva na parte sazonal com $P=1$.

A análise dos gráficos da FAC e da FACP fornecem subsídios para a identificação da ordem de um modelo ARIMA. Contudo, visando maior precisão e agilidade na identificação na ordem do modelo, optou-se por adotar a identificação automática efetuada pela função *auto.arima* do pacote *forecast*, cujos resultados são apresentados na Figura 18.

Figura 18 – Ordem do modelo SARIMA - arroz

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

Coefficients:
      ma1      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
```

Fonte: O autor, 2021.

Conforme indicado na Figura 18, a função *auto.arima* sugere um modelo SARIMA $(0,0,1) \times (1,0,0)_{12}$, i.e., o modelo proposto possui um coeficiente de média móvel de ordem 1 (*ma1* ou $q=1$) na componente não sazonal e um coeficiente autorregressivo de ordem 1 na

componente sazonal (*sar1* ou $P=1$). Cabe ressaltar que, este valor de P se alinha ao resultado da análise da FAC e da FACP. Adicionalmente, conforme indicado pelos p -values na Figura 19, os coeficientes estimados são estatisticamente significativos ao nível de 10%.

Figura 19 – p -values dos coeficientes estimados - arroz

```
> pvalor(modelo)
      mal      sar1  intercept
9.906965e-02 2.046454e-04 3.498839e-26
```

Fonte: O autor, 2021.

A seguir na Tabela 9, apresentam-se os valores da estatística AIC (*Akaike Information Criteria*) de cinco especificações avaliadas através do processo de sobredefinição, dado que o melhor modelo possui o menor AIC. Nesse sentido, o modelo SARIMA(0,0,1)x(1,0,0)₁₂, sugerido pela função *auto.arima*, foi o que apresentou o menor AIC dentre os modelos analisados, sendo portanto o modelo escolhido.


Tabela 9 – Estatística AIC dos modelos avaliados

Modelo	AIC
SARIMA(0,0,1)x(1,0,0) ₁₂	897.84
SARIMA(0,0,0)x(1,0,0) ₁₂	898.31
SARIMA(1,0,1)x(1,0,0) ₁₂	898.64
SARIMA(0,0,1)x(1,0,1) ₁₂	899.75
SARIMA(1,0,1)x(1,0,1) ₁₂	900.55

Fonte: O autor, 2021.

Na Figura 20, o histograma e *qq-plot* dos resíduos e, sobretudo, o p -value do teste de Shapiro-Wilk (0,6905) apontam para a validade da premissa de normalidade assumida no modelo SARIMA(0,0,1)x(1,0,0)₁₂.


Figura 20 – Gráficos da normalidade dos resíduos do modelo - arroz



Fonte: O autor, 2021.

Complementarmente, o gráfico da FAC dos resíduos na Figura 21 e os *p-values* resultantes do teste de Ljung-Box (todos acima de 5%) na Figura 22 indicam a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo.

Figura 21 – FAC dos resíduos do modelo - arroz



Fonte: O autor, 2021.

Figura 22 – *p-values* do Teste Ljung-Box - arroz

lags	statistic	p-value
1	0.1033323	0.7672328
2	1.6473728	0.4455544
3	1.8874705	0.6213786
4	2.0214923	0.7512488
5	2.0293361	0.8561439
6	2.1228552	0.9170829
7	2.1258089	0.9550450
8	2.2085269	0.9710290
9	3.5834258	0.9240759
10	5.7913489	0.8221778
11	7.0181031	0.7782218
12	7.2618438	0.8191808
13	7.2788322	0.8781219
14	7.7716075	0.8921079
15	7.9017020	0.9120879
16	9.4606504	0.8681319
17	9.4608837	0.9000999
18	10.1825935	0.9060939
19	10.4343246	0.9220779
20	10.7380902	0.9390609
21	11.0952696	0.9520480
22	12.2874085	0.9360639
23	12.8894919	0.9430569
24	12.9284178	0.9580420

Fonte: O autor, 2021.

Portanto, as considerações acima permitem concluir que o modelo SARIMA(0,0,1)x(1,0,0)₁₂ é adequado e mostra-se apto à realização das previsões mensais do consumo de arroz. Assim, foram geradas as previsões de consumo de arroz para o exercício de

2019 a partir do modelo ajustado. Na Tabela 10 apresentam-se os valores mensais observados em 2019, os valores previstos, bem como os respectivos desvios relativos.

Tabela 10 – Previsão de consumo para 2019
– arroz - BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	1.380	1.612,74	16,87%
Fev	1.570	1.895,41	20,73%
Mar	1.650	2.144,10	29,95%
Abr	1.620	2.369,48	46,26%
Mai	1.962	1.908,37	2,73%
Jun	1.648	2.113,02	28,22%
Jul	1.809	2.063,80	14,09%
Ago	2.070	2.177,78	5,21%
Set	1.981	1.973,13	0,4%
Out	1.941	2.092,29	7,79%
Nov	1.663	2.011,99	20,99%
Dez	905	1.447,26	59,91%
TOTAL	20.199	23.809,37	17,87%

Fonte: O autor, 2021.

Conforme ilustrado na Tabela 10, a previsão anual para 2019, definida pelo valor total acumulado previsto de consumo de arroz na OM analisada, excedeu ao total observado em 17,87%. A seguir, na Tabela 11 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.


Tabela 11 – Métricas de desempenho

MAPE	MAD	RMSE
21,01%	311,11	376,43

Fonte: O autor, 2021.

Na Figura 23 apresentam-se as previsões mensais para o ano de 2019 (linha em azul), acompanhadas dos respectivos intervalos com confiança de 80% e 95% (áreas em cores cinza escuro e claro), e precedidas pelos dados do período 2014-2018 (linha em preto).

Figura 23 – Previsão de consumo para 2019 - arroz - BJ



Fonte: O autor, 2021.

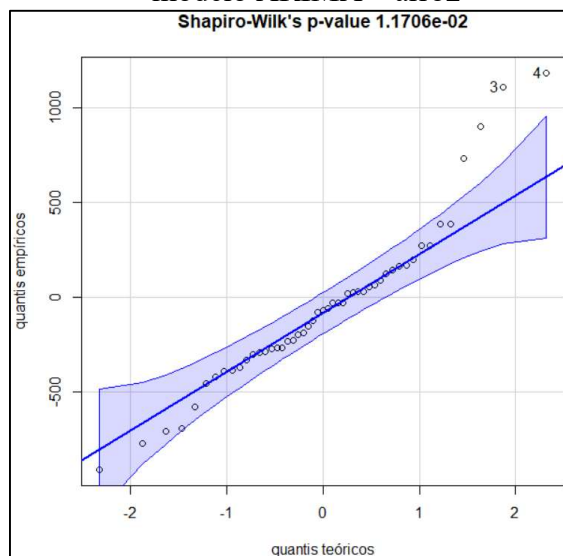
Estes resultados são considerados satisfatórios para o balizamento do planejamento dos gestores da OM, bem como para a elaboração do ETP (ALVES, 2021; BRASIL, 2021; ME, 2020), pois permitem apresentar o embasamento quantitativo dos itens a serem adquiridos por meio dos processos licitatórios.

Além disso, cabe destacar que os resultados obtidos por meio do método de Holt-Winters apresentaram maior aproximação do consumo efetivo no ano de 2019, fato este que se alinha ao mencionado por Petropoulos, Wang e Disney (2019), quando afirmam que o referido método pode gerar melhores resultados do que métodos com aplicações mais complexas. Entretanto, o total acumulado anual obtido pelo somatório das previsões mensais oriundas do método de Holt-Winters (19.115,65 Kg) foi menor do que o efetivamente consumido no ano de 2019 (20.199 Kg), diferentemente do resultado apresentado pelo modelo ARIMA (23.809,37 Kg), que inclui uma margem de segurança para possíveis flutuações da demanda.

Como sugestão de alternativa para obtenção da previsão anual do item, efetuou-se a previsão do acumulado de 12 meses para dezembro do ano de 2019. Neste caso, a função *auto.arima* identificou o modelo ARIMA (0,1,0).

Além disso, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem marginalmente ao pressuposto de normalidade, conforme disposto na Figura 24, em que o *p-value* resultante do teste de Shapiro-Wilk foi da ordem de 1,1706%, portanto, não significativo ao nível de 1%.

Figura 24 – *QQ-plot* dos resíduos do modelo ARIMA – arroz



Fonte: O autor, 2021.

Na Tabela 12 são disponibilizados o valor da previsão anual e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019. A principal virtude desta alternativa consiste em prover um intervalo de confiança da previsão anual e que pode ser útil na definição de uma margem de segurança. Adicionalmente, neste caso, a previsão alternativa apresentou um desvio de 13,85%, valor inferior ao desvio de 17,87% da previsão anual resultante do somatório das previsões mensais.

Tabela 12 – Previsão acumulada para 2019 – arroz – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
20.199	22.997	20.055,33	21.073,55	13,85%

Fonte: O autor, 2021.

Cabe destacar que embora as quantidades registradas no ETP devam ser fundamentadas em previsões baseadas no histórico de consumo e calculadas por meio de métodos quantitativos (ME, 2020), as quantidades estabelecidas nas atas de registro de preços (ARP) advindas dos processos licitatórios, não geram obrigatoriedade de compras por parte dos órgãos públicos (BRASIL, 2021), fato este que reforça a utilidade do intervalo de confiança da previsão de consumo como medida providente às demandas nos estoques das OM da MB.

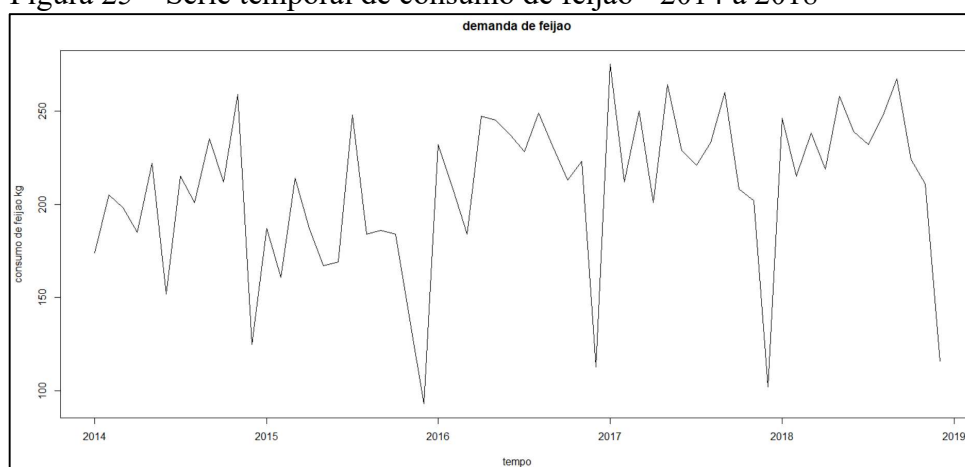
3.3 Análise da previsão de consumo de feijão em uma OM Administrativa

Inicialmente, foram obtidos no sistema Quaestor os dados referentes ao consumo de feijão preto, em Kg, durante o período de 2014 a 2018 em uma OM Administrativa da Força. Em seguida, foi efetuado o carregamento destes dados para o ambiente do *software* R de forma que fosse iniciado o processo de análise para a obtenção da previsão de consumo do item para o exercício de 2019.

Cabe ressaltar que os dados de consumo do feijão no período de 2014 a 2018 foram utilizados para o treinamento do modelo de previsão, que posteriormente foi empregado para o fornecimento das previsões de consumo do item para 2019.

Conforme recomendado por Souza e Camargo (1996), a análise iniciou-se com a geração do gráfico da série temporal do consumo do gênero alimentício (Figura 25) durante o período designado para ajuste do modelo preditivo.

Figura 25 – Série temporal de consumo de feijão - 2014 a 2018




Fonte: O autor, 2021.

Em uma análise visual, a série temporal em questão expõe a presença de uma sazonalidade, embora não seja nítida a visualização da componente de tendência. No que tange à sazonalidade, o gráfico exposto na Figura 25 indica uma possível sazonalidade aditiva, haja vista a constância da amplitude dos consumos ao longo do período analisado, o que sugere a aplicação do modelo aditivo para o método de Holt-Winters.

Em seguida, foi realizada a decomposição da série temporal (Figura 26) em suas componentes não observáveis, quais sejam: tendência, sazonalidade e irregular. Tal procedimento viabiliza um melhor grau de detalhamento na análise exploratória dos dados,

indicando possíveis informações gerenciais acerca da OM analisada, tais como o período sazonal de consumo e a tendência de utilização do referido gênero alimentício.

Figura 26 - Decomposição da série temporal do consumo de feijão



Fonte: O autor, 2021.

Após a decomposição da série em suas componentes não observáveis, foi possível verificar na Figura 26 que a componente de tendência indica flutuações nos anos de 2014 e 2015, um crescimento em 2016 e certa estabilidade no consumo nos anos de 2017 e 2018. Este aspecto sugere ao gestor de Município daquela OM certa cautela quanto ao planejamento dos estoques para o exercício de 2019, uma vez que variações significativas nas contratações em relação aos últimos anos, poderiam comprometer as demandas do item na produção das refeições na OM em 2019.

Além disso, observou-se através da componente de sazonalidade, quedas bruscas no consumo de feijão durante o mês de dezembro. De uma forma geral, o mês de dezembro caracteriza-se como um período utilizado para o gozo de férias por boa parte da tripulação, além de ser um período de recesso administrativo no setor público, o que implica na redução do consumo dos itens de estoque de alimentos.

3.3.1 Previsão de consumo de feijão baseada no método de Holt-Winters

Após a realização da análise exploratória dos dados de consumo de feijão durante o período de 2014 a 2018 na OM Administrativa, foram geradas as constantes de alisamento do modelo aditivo de HW, utilizando-se a função *HoltWinters* do *software* R (BARROS *et al.*,

2020). As constantes de alisamento ou parâmetros de suavização resultantes são apresentadas na Tabela 13.

Tabela 13 – Parâmetros de suavização - feijão

Item	alfa	beta	gama
Feijão	0,1897	0,0247	0,6583

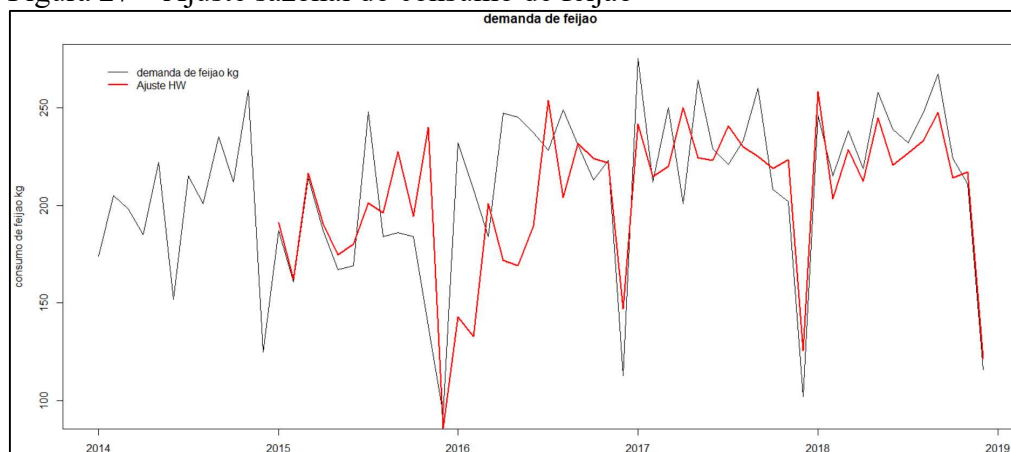
Fonte: O autor, 2021.

No que concerne aos parâmetros α e β , foi possível observar que estes apresentaram valores mais próximos à zero, indicando que o modelo considera os dados mais antigos da série temporal com pesos maiores nas equações de nível e tendência.

Em paralelo, o parâmetro γ , atrelado à componente sazonal, apresentou um valor mais próximo a 1, o que, conforme Barros *et al.* (2020), indica que um peso maior é atribuído aos dados mais recentes no ajuste do modelo preditivo.

A Figura 27 a seguir ilustra a série temporal de consumo de feijão (em preto) e as estimativas mensais (em vermelho) resultantes do ajuste do modelo de aditivo de Holt-Winters. No processo de ajuste, em que foram utilizados os dados do período de 2014 a 2018 para o treinamento do modelo, observou-se, conforme a linha vermelha da Figura 27, que o modelo foi bem ajustado para o ano de 2018, indicando que poderão ser obtidas boas previsões para 2019 a partir do modelo obtido pelo método de Holt-Winters.

Figura 27 – Ajuste sazonal do consumo de feijão



Fonte: O autor, 2021.

Após o referido ajuste, foram obtidas as previsões mensais, até 12 passos à frente, referentes ao consumo de feijão, mês a mês, correspondentes ao exercício de 2019, em uma OM Administrativa da MB. Para a obtenção das previsões utilizou-se a função *forecast* do pacote *forecast* do software R (HYNDMAN; KHADANKAR, 2008).

A Tabela 14 apresenta os valores observados em 2019, bem como os respectivos valores previstos. Na parte inferior da Tabela 14 observa-se o somatório dos valores estimados mensalmente, o que gera uma perspectiva de consumo do item ao longo do ano na OM analisada. Destaca-se que o desvio relativo foi de 0,15% entre o consumo anual observado e o consumo anual previsto, aproximando-se em 99,85% do total efetivamente consumido em 2019.

Tabela 14 – Previsão de consumo para 2019
– feijão – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	254	263,89	3,89%
Fev	229	224,51	1,96%
Mar	249	246,76	0,90%
Abr	227	227,63	0,28%
Mai	262	262,62	0,24%
Jun	245	238,89	2,50%
Jul	232	234,75	1,19%
Ago	229	244,84	6,92%
Set	264	259,70	1,63%
Out	226	217,46	3,78%
Nov	222	210,02	5,39%
Dez	112	115,82	3,41%
TOTAL	2.751	2.746,89	0,15%

Fonte: O autor, 2021.

A Tabela 15 a seguir apresenta as métricas MAPE, MAD e RMSE, referentes aos valores mensais.

Tabela 15 – Métricas de desempenho

MAPE	MAD	RMSE
2,67%	5,93	7,47

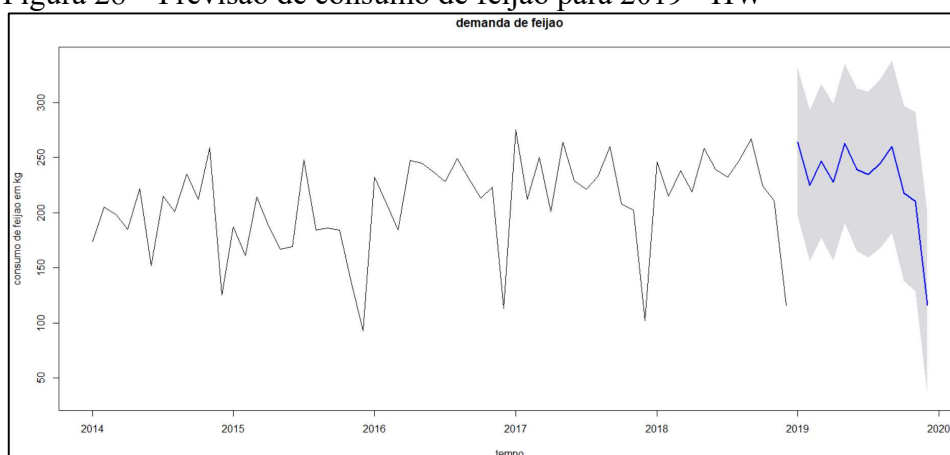
Fonte: O autor, 2021.

Tendo em vista que a IN nº 40/2020 do ME e a Lei nº 14.133/2021 preconizam a elaboração de estimativas com base no consumo anual (ALVES, 2021; BRASIL, 2021), o processo de previsão de consumo para a OM em questão apresentou resultados que refletem os padrões de consumo do referido item naquela instituição. Nesse sentido, a metodologia empregada para obtenção do resultado em questão apresenta-se como um possível parâmetro de composição do processo de planejamento das compras de alimentos das OM da MB, principalmente no que tange à elaboração dos ETP.

Sendo assim, os resultados alcançados podem proporcionar ao gestor de Municíamento da OM Administrativa, informações gerenciais a serem utilizadas nas tomadas de decisões da OM, inclusive no que se refere à política de compras do item e ao reabastecimento do estoque de alimentos.

A seguir é possível observar por meio da Figura 28, as previsões mensais (linha em azul) na sequência dos valores observados (linha em preto) e acompanhadas dos intervalos de previsão com 95% de confiança, que indicam as magnitudes das incertezas.

Figura 28 – Previsão de consumo de feijão para 2019 - HW



Fonte: O autor, 2021.

A soma das previsões mensais para gerar uma previsão anual atende ao disposto na Instrução Normativa nº 40/2020 do ME. Contudo, com o propósito de se obter um intervalo de confiança que esteja associado à previsão anual, utilizou-se o procedimento que consiste no cálculo da previsão do consumo acumulado nos últimos 12 meses para dezembro de 2019 (previsão 12 passos à frente), a partir da série mensal do consumo acumulado de 12 meses.

A aplicação do método de Holt-Winters na série de consumo mensal acumulado de 12 meses produziu a previsão de consumo anual na Tabela 16.

Tabela 16 – Previsão acumulada para 2019 – feijão - HW

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
2.751	2.811,74	2.511,87	3.111,61	2,21%

Fonte: O autor, 2021.

A previsão alternativa apresentou um desvio relativo de 2,21%, valor este superior ao desvio de 0,15% da previsão anual resultante do somatório das previsões mensais.

Nesse sentido, foi possível constatar que as previsões obtidas pelos dois métodos apresentados proporcionaram resultados satisfatórios quando comparados aos valores observados extraídos do sistema Quaestor. O primeiro método fornece ao gestor de Municípios da OM uma projeção do fluxo de saída do item no estoque da OM, norteando o volume de consumo mensal, bem como fornecendo uma perspectiva dos recursos orçamentários-financeiros a serem empregados na manutenção do fornecimento das refeições na OM.

Além disso, cabe destacar que a série temporal de consumo de feijão tende a apresentar menores flutuabilidades na demanda, haja vista ser este um item utilizado quase que diariamente nas refeições das OM da MB.

3.3.2 Previsão de consumo de feijão baseada na metodologia Box & Jenkins

Em seguida foi utilizada a função *auto.arima* do *software* R de forma que fosse obtida a sugestão inicial de um modelo para a obtenção das previsões mensais de consumo de feijão (SOUZA, 2020). Na Figura 29 observa-se que foi sugerido inicialmente um modelo SARIMA $(0,0,0) \times (1,1,0)_{12}$, i.e., o modelo possui um coeficiente autorregressivo na componente sazonal (*sar1* ou $P=1$), além de indicar a uma diferenciação de primeira ordem ($D=1$) na parte sazonal.

Figura 29 – Ordem inicial do modelo SARIMA - feijão

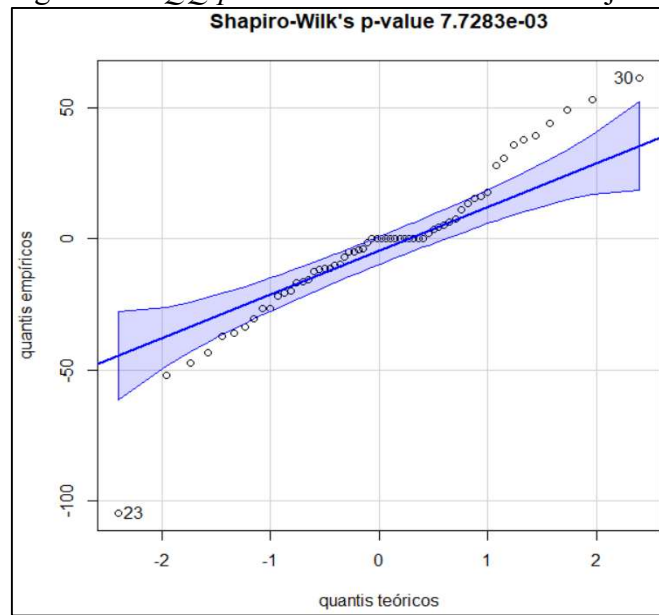
```
> modelo=auto.arima(serie)
> summary(modelo)
Series: serie
ARIMA(0,0,0)(1,1,0)[12] with drift

Coefficients:
      sar1    drift
    -0.6050  0.8732
s.e.    0.1182  0.2595

sigma^2 estimated as 984.7:  log likelihood=-235.24
AIC=476.48  AICc=477.02  BIC=482.09
```


Fonte: O autor, 2021.

Na sequência, na Figura 30 foi gerado o *qq-plot* dos resíduos, e observou-se que o *p-value* do teste de Shapiro Wilk (0,0077283) apontou para a rejeição da hipótese de normalidade dos resíduos, premissa esta fundamental à validação do modelo para a obtenção das previsões.

Figura 30 – *QQ-plot* do modelo SARIMA - feijão

Fonte: O autor, 2021.

Ao analisar os valores de consumo do item ao longo dos meses do período de 2014 a 2018, foi possível identificar a presença de dois meses considerados *outliers* em relação aos demais valores de consumo na OM analisada, os quais correspondem aos meses de dezembro de 2015 e 2017, 93 Kg e 102 Kg, respectivamente, evidenciados na Figura 31.

Figura 31 – *Boxplot* da série de consumo de feijão

Fonte: O autor, 2021.

Desta forma, foram criadas variáveis *dummies* para a retirada da influência dos *outliers* no processo de ajuste do modelo. Em seguida, foi executada novamente a função *auto.arima*, de forma a se obter uma nova sugestão de modelo com a intervenção das referidas variáveis. O resultado obtido encontra-se ilustrado na Figura 32.

Figura 32 – Ordem do modelo SARIMA - feijão

```

> dummy[24]=1
> dummy[48]=1
> modelo=auto.arima(serie,xreg=dummy)
> summary(modelo)
Series: serie
Regression with ARIMA(2,1,1)(1,0,0)[12] errors

Coefficients:
      ar1      ar2      ma1      sar1      xreg
    0.0815  0.2377 -0.9728  0.5185 -31.9390
s.e.  0.1566  0.1457  0.0629  0.1406  24.8411

sigma^2 estimated as 1192:  log likelihood=-292.63
AIC=597.26  AICc=598.88  BIC=609.73


```

Fonte: O autor, 2021.

Conforme ilustrado na Figura 32, após a inclusão das variáveis *dummies* a função *auto.arima* sugeriu um modelo SARIMA (2,1,1)x(1,0,0)₁₂, i.e., um modelo com dois coeficientes autorregressivos (*ar1* e *ar2* ou $p=2$) e um coeficiente de média móvel de ordem 1 (*ma1* ou $q=1$) na componente não sazonal, além de sugerir uma diferenciação de ordem 1 ($d=1$) na referida componente. Na componente sazonal, sugeriu um coeficiente autorregressivo de ordem 1 (*sar1* ou $P=1$).

Na Figura 33, o histograma e *qq-plot* dos resíduos e, sobretudo, o *p-value* do teste de Shapiro-Wilk (0,36886) apontam para a validade da premissa de normalidade assumida no modelo SARIMA (2,1,1)x(1,0,0)₁₂.


Figura 33 – Gráficos de normalidade dos resíduos do modelo - feijão



Fonte: O autor, 2021.

Complementarmente, o gráfico da FAC dos resíduos na Figura 34 indica a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo.

Figura 34 – FAC dos resíduos do modelo - feijão



Fonte: O autor, 2021.

Em consonância ao observado no gráfico da FAC na Figura 34, observou-se os *p-values* do teste de Ljung-Box (todos acima de 5%) na Figura 35, o que ratifica a constatação da ausência de estrutura de autocorrelação entre os resíduos do modelo.

Figura 35 – *p-values* do Teste Ljung-Box - feijão

lags	statistic	p-value
1	0.1085779	0.7602398
2	0.2732933	0.8931069
3	0.3418322	0.9590410
4	2.0448818	0.7462537
5	3.1968804	0.6773227
6	3.3202581	0.7702298
7	3.5296124	0.8321678
8	4.0345161	0.8461538
9	4.1056230	0.8901099
10	4.2567083	0.9270729
11	4.2639803	0.9570430
12	5.4343308	0.9360639
13	5.5921723	0.9570430
14	6.1910163	0.9630370
15	7.0078063	0.9540460
16	7.5274469	0.9580420
17	7.6385062	0.9690310
18	9.3909166	0.9370629
19	9.5620116	0.9510490
20	9.7844397	0.9650350
21	10.9391664	0.9580420
22	11.2516431	0.9680320
23	11.2917181	0.9790210
24	16.0038702	0.8621379

Fonte: O autor, 2021.

Portanto, a análise dos resíduos permite concluir que o modelo SARIMA $(2,1,1) \times (1,0,0)_{12}$ é adequado (BARROS *et al.*, 2020) e mostra-se apto à realização das previsões mensais do consumo de feijão. Assim, foram geradas as previsões de consumo de feijão para o

exercício de 2019 a partir do modelo ajustado. Na Tabela 17 apresentam-se os valores mensais observados em 2019, os valores previstos, bem como os respectivos desvios relativos.

Tabela 17 – Previsão de consumo para 2019
– feijão – BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	254	227,22	10,54%
Fev	229	201,28	12,11%
Mar	249	225,03	9,63%
Abr	227	213,80	5,82%
Mai	262	236,72	9,65%
Jun	245	226,76	7,45%
Jul	232	223,76	3,55%
Ago	229	231,56	1,12%
Set	264	242,08	8,30%
Out	226	219,81	2,74%
Nov	222	213,11	4,01%
Dez	112	163,86	46,30%
TOTAL	2.751	2.624,99	4,58%

Fonte: O autor, 2021.

Conforme ilustrado na Tabela 17, a previsão anual para 2019, definida pelo valor total acumulado previsto de consumo de feijão na OM analisada, aproximou-se em 95,42% do total efetivamente consumido naquele exercício. A seguir, na Tabela 18 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.


Tabela 18 – Métricas de desempenho

MAPE	MAD	RMSE
10,10%	19,57	23,40

Fonte: O autor, 2021

Os resultados encontrados são passíveis de serem utilizados para o planejamento das aquisições do item, sobretudo na elaboração dos ETP que compõe o processo licitatório das aquisições de gêneros alimentícios. Na Figura 36 apresentam-se as previsões mensais de consumo de feijão para o exercício de 2019 (linha em azul), acompanhadas dos respectivos intervalos de confiança de 80% e 95% (áreas em cores cinza escuro e claro), que, conforme Pujarati e Seshadri (2019), representam as magnitudes das incertezas.

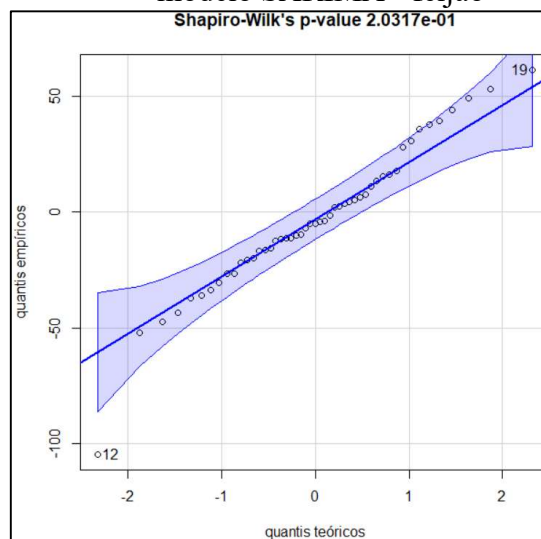
Figura 36 – Previsão de consumo de feijão para 2019 - BJ



Fonte: O autor, 2021

Como sugestão de alternativa para a obtenção da previsão anual do item, efetuou-se a previsão do acumulado de 12 meses para dezembro do ano de 2019. Neste caso, a função *auto.arima* identificou o modelo SARIMA (0,1,0)x(1,0,0). Além disso, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem marginalmente ao pressuposto de normalidade (MORETTIN; TOLOI, 2018), conforme disposto na Figura 37, em que o *p-value* resultante do teste de Shapiro-Wilk foi da ordem de 20,32%, portanto, não significativo ao nível de 10%.

Figura 37 – *QQ-plot* dos resíduos do modelo SARIMA - feijão



Fonte: O autor, 2021

Na Tabela 19 são disponibilizados o valor da previsão anual de consumo de feijão, em Kg, e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019. A principal virtude desta alternativa consiste em prover um

intervalo de confiança da previsão anual e que pode ser útil na definição de uma margem de segurança a ser inserida no ETP, e por conseguinte na ata de registro de preços (ARP) do item, que possui como característica a não obrigatoriedade de contratação da totalidade dos itens (BRASIL, 2021), possibilitando assim a inserção da referida margem com o propósito de amortecer possíveis flutuações da demanda (BALLOU, 2006).

Adicionalmente, neste caso, a previsão alternativa apresentou um desvio de 8,90%, valor este superior ao desvio de 4,58% da previsão anual resultante do somatório das previsões mensais.

Tabela 19 – Previsão acumulada para 2019 – feijão – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
2.751	2.995,78	2.856,47	3.135,10	8,90%

Fonte: O autor, 2021.

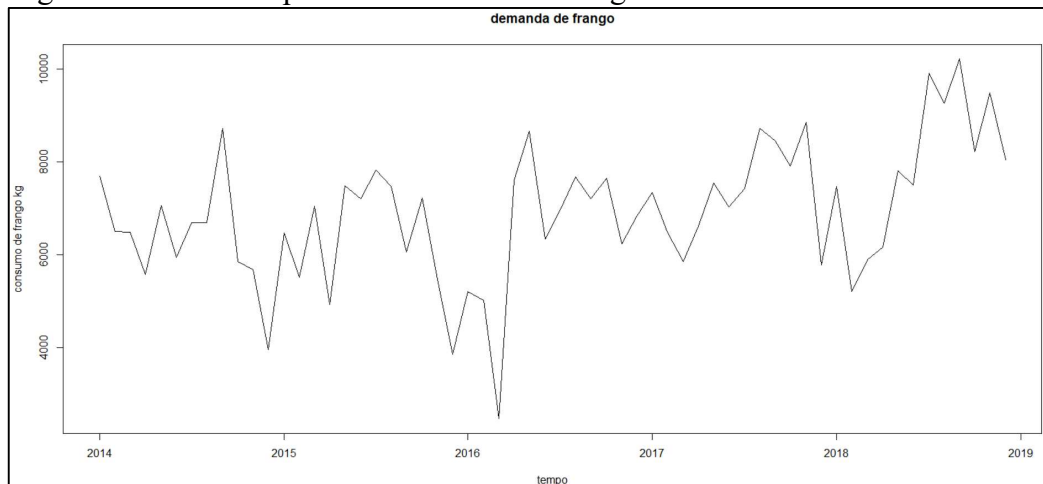
Embora o desvio relativo tenha sido maior no método alternativo, a utilização do intervalo de confiança pode mitigar o risco da necessidade de realização de aditivos no contrato de fornecimento dos gêneros alimentícios, sendo, portanto, uma medida previdente para a gestão dos estoques de alimentos da MB.

3.4 Análise da previsão de consumo de frango em um Hospital Naval

Para a realização da análise do processo preditivo de consumo de peito de frango, em Kg, para o ano de 2019 em um hospital da MB, foi gerado inicialmente a série temporal de consumo do referido item durante o período de 2014 a 2018. Assim como nas demais análises realizadas anteriormente, os dados históricos de consumo foram coletados no sistema Quaestor na DFM.

Após o carregamento dos dados para o ambiente do *software* R, foi gerado o gráfico da série temporal de consumo do item no período utilizado para o treinamento do modelo preditivo (2014-2018), conforme ilustrado na Figura 38.

Figura 38 - Série temporal do consumo de frango – HN – 2014 a 2018

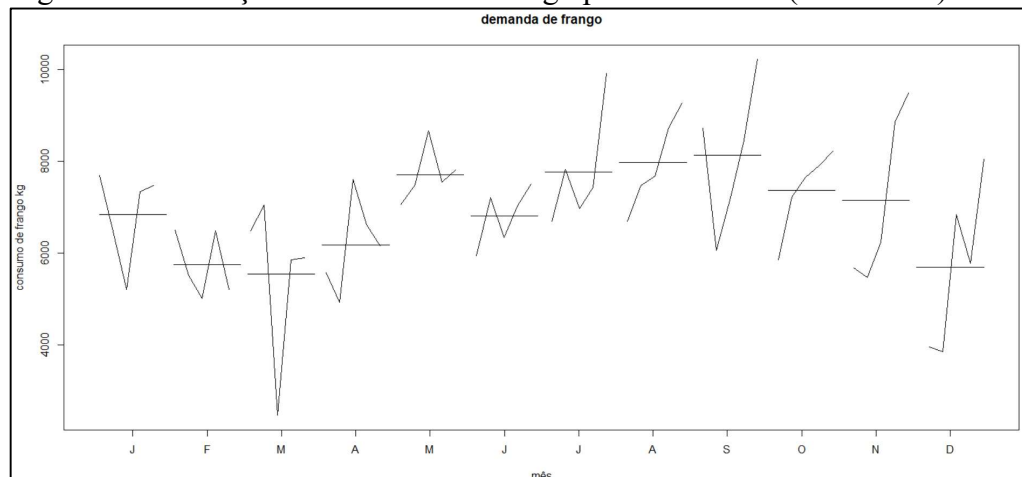


Fonte: O autor, 2021.

Cabe destacar que o Hospital Naval (HN) em análise realiza atendimentos de média e alta complexidade aos militares e seus dependentes, e dispõe de uma estrutura com mais de 600 leitos. Além disso, o HN possui 60 clínicas e mais de 100 consultórios. Este porte torna a gestão de estoque de alimentos na OM, uma atividade complexa para os gestores, uma vez que, a oscilação do consumo dos itens, como pode ser observado na Figura 38, pode dificultar a identificação das componentes de tendência e sazonalidade.

Para isto, utilizou-se a função *monthplot* do *software* R de forma que fosse possível observar de forma mais detalhada as características de consumo mensal do item. Destaca-se que o frango é um item frigorificado com alto nível de consumo nas OM da MB, inclusive no HN analisado. A Figura 39 expõe a oscilação das médias de consumo por mês durante o período de 2014 a 2018.

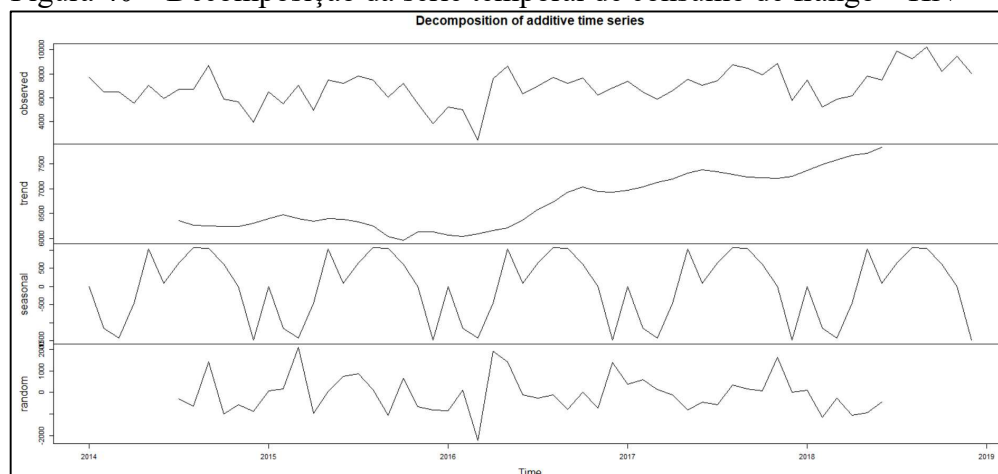
Figura 39 – Variação do consumo de frango por mês no HN (2014-2018)



Fonte: O autor, 2021.

A Figura 39 demonstra certa variação da média de consumo quando observado os meses de forma isolada. Entretanto, com a exceção dos meses de fevereiro e abril, observa-se um movimento crescente de consumo do item nos demais meses. Cabe destacar que o frango é um bem substituto à carne vermelha, que costuma apresentar maiores preços de mercado. A seguir, foi realizada a decomposição da série em suas componentes não observáveis (Figura 40).

Figura 40 – Decomposição da série temporal de consumo de frango – HN



Fonte: O autor, 2021.

Conforme observado na Figura 40, a componente de tendência demonstra um movimento crescente do consumo do frango no HN, se alinhando de uma forma geral à análise das médias mensais de consumo do item (Figura 39). A sazonalidade indica reduções de consumo no mês de dezembro, tendo em vista que neste período ocorre o gozo de férias de parte da tripulação da OM, e por ser o período de recesso administrativo nos órgãos do setor público.

3.4.1 Previsão de consumo de frango em um HN baseada no método de Holt-Winters

Para a obtenção das previsões mensais de consumo de frango, em Kg, para o exercício de 2019, foi utilizado modelo aditivo do método de Holt-Winters. A Tabela 20 expõe os parâmetros de suavização para o ajuste do modelo preditivo de Holt-Winters.

Tabela 20 – Parâmetros de suavização – frango – HN


Item	alfa	beta	gama
Frango	0.0119	0.6817	0.4149

Fonte: O autor, 2021.

Como pode ser observado, os valores de α e γ , referentes às componentes de nível e sazonalidade, apresentaram valores mais próximos à zero, o que indica que as estimativas para estas componentes têm peso maior nas observações mais antigas. O parâmetro β apresentou valor próximo à um, indicando que a estimativa de tendência tem peso maior nas observações mais recentes (BARROS *et al.*, 2020).

A seguir, a Figura 41 apresenta o gráfico de consumo de peito de frango, em Kg, no Hospital Naval (linha preta) em conjunto com o ajuste via Holt-Winters (linha vermelha).

Figura 41 – Ajuste sazonal de consumo de frango – HN



Fonte: O autor, 2021.

Após o ajuste do modelo preditivo de Holt-Winters, foi gerada a previsão para o exercício de 2019 referente ao consumo de peito de frango, em Kg, no Hospital Naval analisado. Nesse sentido, foi utilizada a função *forecast* do *software* R para a obtenção das previsões até 12 passos à frente, referentes ao consumo de peito de frango, mês a mês, em Kg, para o exercício de 2019. A Tabela 21 dispõe dos valores observados extraídos do Quaestor, bem como dos valores previstos gerados no *software* R. Na parte inferior da Tabela 21 é possível observar os valores anuais de consumo de frango, em Kg, em 2019, com um desvio relativo de 6,58% entre o consumo anual observado e o consumo anual previsto.

Tabela 21 – Previsão de consumo para 2019
– frango – HN – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	9.988	8.225,84	17,64%
Fev	4.316	6.902,77	59,93%
Mar	5.312	7.049,95	32,71%
Abr	6.215	7.716,45	24,16%
Mai	7.587	9.344,05	23,16%
Jun	7.492	8.773,60	17,11%
Jul	10.300	10.012,87	2,79%
Ago	10.563	10.190,47	3,53%
Set	10.202	10.625,55	4,15%
Out	12.079	9.532,30	21,08%
Nov	9.012	9.957,91	10,50%
Dez	7.063	8.384,22	18,71%
TOTAL	100.129	106.715,98	6,58%

Fonte: O autor, 2021.

Ainda referente aos resultados dispostos na Tabela 21, verificou-se que as quantidades efetivamente consumidas do gênero alimentício no período de fevereiro a maio de 2019 apresentaram maiores desvios relativos quando comparadas com os demais meses do ano. Desta forma, a referida constatação pode sinalizar ao controle interno da Força uma possível verificação das causas dos desvios encontrados, fortalecendo assim a mitigação dos riscos de falhas administrativas, além de se alinhar aos preceitos inerentes à Teoria dos Contratos, que traz vínculo com os aspectos de controle, requerendo o embasamento quantitativo robusto das quantidades dos materiais inseridas nos contratos.

Nesse escopo, é possível observar que a metodologia empregada para obter as previsões pode ser útil à identificação de possíveis anormalidades no fluxo de entrada e saída dos itens em estoque, o que se alinha ao mencionado por Ching (2016), que destaca que a gestão de estoques tem a responsabilidade de planejar e controlar o fluxo dos itens nos estoques, além de identificar e corrigir possíveis anormalidades frente às previsões realizadas previamente.

O mecanismo proposto ainda pode ser útil em auditorias e inspeções realizadas pelo Centro de Controle Interno da Marinha (CCIMAR) e pela DFM no Municíamento das OM da MB, uma vez que permite identificar desvios com valores expressivos frente ao planejamento e controle dos gestores, podendo ensejar em medidas corretivas e de aperfeiçoamento na gestoria de Municíamento da Força.

Adicionalmente, na Tabela 22, apresentam-se as métricas de desempenho MAPE, MAD e RMSE referentes aos valores mensais.


Tabela 22 – Métricas de desempenho

MAPE	MAD	RMSE
19,62%	1.377	1.563,32

Fonte: O autor, 2021.

Numa perspectiva anual, verificou-se que o montante total de consumo previsto excedeu em 6,58% do total efetivamente consumido. Adicionalmente, na Figura 42 tem-se a visualização das previsões mensais (linha em azul) na sequência dos valores observados e acompanhados dos intervalos de previsão com 95% de confiança que indicam as magnitudes das incertezas.

Figura 42 – Previsão de consumo de frango para 2019 – HN – HW



Fonte: O autor, 2021.

Embora o período de fevereiro a junho tenha apresentado maiores defasagens entre o previsto e o observado, a previsão de consumo anual apresentou resultados que atendem ao contido na Instrução Normativa nº 40/2020 do ME, quando da elaboração do ETP. Contudo, visando a obtenção do intervalo de confiança associado à previsão anual, foi empregado o procedimento alternativo que viabiliza a obtenção do consumo acumulado nos últimos 12 meses para dezembro de 2019 (previsão 12 passos à frente), a partir da série mensal do consumo acumulado de 12 meses. Com isto, a aplicação do método de Holt-Winters na série de consumo mensal acumulado de 12 meses produziu a previsão de consumo anual na Tabela 23.

Tabela 23 – Previsão acumulada para 2019 – frango – HN – HW

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
100.129	102.154,12	91.781,12	112.527,12	2,02%

Fonte: O autor, 2021.

Conforme visualizado na Tabela 23, a previsão pontual obtida pelo procedimento alternativo apresentou um desvio relativo menor do que somatório das previsões mensais. Cabe destacar que em ambos os casos as previsões forneceram valores maiores do que o efetivamente consumido em 2019, embora o valor obtido pelo método alternativo tenha sido mais moderado, evitando, conforme Saavedra-Nieves (2018), o risco de se ter capital imobilizado desnecessariamente no estoque de alimentos da OM.

Adicionalmente, a metodologia utilizada para a obtenção das previsões, operacionalizada por meio do *software* R, se alinha à necessidade de a administração pública prover os seus gestores de ferramentas tecnológicas capazes de proporcionar maior precisão nas atividades contábeis dos órgãos, conforme mencionado por Alencar e Fonseca (2016).

Devido ao grande porte da OM e à complexidade em sua gestão de estoques de alimentos, que conforme Santos e Oliveira (2016), é proporcional ao volume de itens em estoque, torna-se prudente a inserção de uma margem de segurança na previsão do item a ser considerada na elaboração do ETP de gêneros alimentícios da OM.


Ressalta-se que a previsão anual busca uma solução para a consecução dos objetivos de mitigar os aditivos dos contratos de fornecimento de alimentos utilizados em muitos casos para cobrir falhas no abastecimento dos estoques e a para a redução de custos de armazenagem das sobras.

A previsão do acumulado de 12 meses para dezembro de 2019 vem acompanhada de um intervalo de confiança que fornece uma medida do grau de incerteza da previsão anual. Além disso, o intervalo de confiança e o contraste entre as previsões anuais nas Tabelas 21 e 23 fornecem subsídios para a definição de uma margem de segurança da previsão do item.

3.4.2 Previsão de consumo de frango em um HN baseada na metodologia Box & Jenkins

Na sequência, a FAC e a FACP da série do consumo mensal de peito de frango são apresentadas nas Figuras 43 e 44 respectivamente.

Figura 43 – FAC da série de consumo de frango - HN




Fonte: O autor, 2021.

No gráfico da FAC (Figura 43) é possível observar um pico no *lag* 1,0 que corresponde a 12 meses, indicando a presença de sazonalidade, e como consequência, a presença da componente autorregressiva na parte sazonal de um modelo SARIMA. A identificação da ordem P da componente autorregressiva sazonal é sugerida por meio da inspeção da FACP na Figura 44.

A FACP na Figura 44 exibe duas autocorrelações parciais significativas, sugerindo inicialmente um modelo que detenha uma componente autorregressiva na parte sazonal. Entretanto, será observada a sugestão fornecida pela funcionalidade *auto.arima*.

Figura 44 – FACP da série de consumo de frango - HN



Fonte: O autor, 2021.

A análise dos gráficos da FAC e da FACP (Figuras 43 e 44) proporcionam a extração de subsídios importantes para a identificação da ordem de um modelo ARIMA. Entretanto, com o propósito de se obter maior precisão e otimização na identificação da ordem do modelo a ser

utilizado, adotou-se o mecanismo de identificação automática efetuada pela função *auto.arima* do pacote *forecast*, cujos resultados são apresentados na Figura 45.

Figura 45 – Ordem do modelo SARIMA – frango - HN

```
> modelo=auto.arima(serie)
> summary(modelo)
Series: serie
ARIMA(0,1,1)(1,0,0)[12]

Coefficients:
      mal      sar1
    -0.7873  0.3620
s.e.   0.2012  0.1477

sigma^2 estimated as 1643288:  log likelihood=-506.22
AIC=1018.43  AICc=1018.87  BIC=1024.66
```

Fonte: O autor, 2021.

Conforme indicado na Figura 45, a função *auto.arima* sugere um modelo SARIMA $(0,1,1) \times (1,0,0)_{12}$, i.e., o modelo proposto possui um coeficiente de média móvel de ordem 1 (*ma1* ou $q=1$) na componente não sazonal e um coeficiente autorregressivo de ordem 1 na componente sazonal (*sar1* ou $P=1$). Além disso, foi sugerida uma diferenciação de ordem 1 ($d=1$) na parte não sazonal para a remoção da tendência.


Figura 46 – *p-values* dos coeficientes estimados – frango - HN

```
> pvalor(modelo)
      mal      sar1
0.0002451819 0.0173727335
```

Fonte: O autor, 2021.

Adicionalmente, conforme indicado pelos *p-values* na Figura 46, os coeficientes estimados são estatisticamente significativos ao nível de 5%. Na Figura 47, o histograma e *qq-plot* dos resíduos e, sobretudo, o *p-value* do teste de Shapiro-Wilk ($0,7884$) apontam para a validade da premissa de normalidade assumida no modelo SARIMA $(0,1,1) \times (1,0,0)_{12}$.

Figura 47 – Gráficos da normalidade dos resíduos do modelo – frango - HN



Fonte: O autor, 2021.

Figura 48 – *p-values* do Teste Ljung-Box – frango - HN

lags	statistic	p-value
1	0.6445096	0.43056943
2	2.2911632	0.32867133
3	2.5051315	0.50049950
4	2.5870754	0.64835165
5	9.4547797	0.10089910
6	10.4327350	0.10589411
7	17.5842113	0.01698302
8	17.5933942	0.02597403
9	17.6014269	0.04795205
10	19.2257518	0.03996004
11	20.6368883	0.03996004
12	20.7810949	0.06293706
13	21.8648650	0.06393606
14	22.1167354	0.08091908
15	22.5314712	0.09390609
16	22.9245181	0.12587413
17	23.4591946	0.14185814
18	25.2908294	0.12487512
19	25.6687789	0.15484515
20	26.6925936	0.15684316
21	26.8157443	0.19080919
22	27.7518312	0.20279720
23	29.3323319	0.19580420
24	30.3303209	0.20179820

Fonte: O autor, 2021.

Complementarmente, os *p-values* resultantes do teste de Ljung-Box (todos acima de 1%) na Figura 48 indicam a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo. Portanto, as referidas considerações permitem concluir que o modelo SARIMA (0,1,1)x(1,0,0)₁₂ é adequado (BARROS *et al.*, 2020) e mostra-se apto à realização das previsões mensais do consumo de frango no Hospital Naval. Assim, foram geradas as previsões de consumo de peito de frango, em Kg, para o exercício de 2019 a partir do modelo ajustado. Na Tabela 24 apresentam-se os valores mensais observados em 2019, os valores previstos, bem como os respectivos desvios relativos.

Tabela 24 – Previsão de consumo para 2019 – frango – HN – BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	9.988	8.513,80	14,76%
Fev	4.316	7.693,92	78,27%
Mar	5.312	7.942,23	49,51%
Abr	6.215	8.038,52	29,34%
Mai	7.587	8.634,70	13,81%
Jun	7.492	8.522,85	13,76%
Jul	10.300	9.399,56	8,74%
Ago	10.563	9.162,46	13,26%
Set	10.202	9.508,15	6,80%
Out	12.079	8.783,11	27,29%
Nov	9.012	9.243,91	2,57%
Dez	7.063	8.722,30	23,49%
TOTAL	100.129	104.165,51	4,03%

Fonte: O autor, 2021.

Conforme ilustrado na Tabela 24, a previsão anual de consumo de frango para 2019, definida pelo valor total acumulado no HN, excedeu ao total observado em 4,03%. Conforme mencionado anteriormente, diante do mencionado achado, o controle interno da MB pode se valer do mencionado achado para verificar as possíveis causas que acarretaram em uma redução do consumo do frango naquele período, gerando assim maiores desvios relativos em relação aos valores previstos para aqueles meses. A seguir, na Tabela 25 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.


Tabela 25 – Métricas de desempenho

MAPE	MAD	RMSE
23,47%	1.630,53	1.891,01

Fonte: O autor, 2021.

Na Figura 49 apresentam-se as previsões mensais para o ano de 2019 (linha em azul), acompanhadas dos respectivos intervalos de confiança de 80% e 95% (áreas em cores cinza escuro e claro), e precedidas pelos dados do período de 2014 a 2018 (linha em preto).

Figura 49 – Previsão de consumo de frango para 2019 – HN – BJ



Fonte: O autor, 2021.

Nesse sentido, cabe destacar que os resultados obtidos no processo de previsão são considerados satisfatórios para o balizamento dos gestores da OM, bem como para a elaboração do ETP. Entretanto os entraves administrativos junto ao fornecedor do item no primeiro semestre de 2019 devem ser levados em consideração no planejamento de contratações futuras que abarque os dados de consumo de 2019.


Além disso, o resultado da soma dos meses obtido pela metodologia Box & Jenkins (104.165 Kg) apresentou maior aproximação do consumo efetivo do ano de 2019 (100.129 Kg)

do que o resultado oriundo do método de Holt-Winters (106.715,98 Kg). Vale destacar que em ambos os métodos o total previsto superou ao efetivamente consumido, não acarretando risco de desabastecimento do item.

Como sugestão alternativa para obtenção da previsão anual do frango no Hospital Naval, executou-se a previsão do acumulado de 12 meses para dezembro do ano de 2019. Neste caso, a função *auto.arima* identificou o modelo SARIMA (0,1,0)x(0,0,1).

Além disso, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem marginalmente ao pressuposto de normalidade, conforme disposto na Figura 50, em que o *p-value* resultante do teste de Shapiro-Wilk foi da ordem de 1,3448%, portanto, não significativo ao nível de 1%.

Figura 50 – *QQ-plot* dos resíduos do modelo SARIMA – frango - HN



Fonte: O autor, 2021.

Na Tabela 26 são disponibilizados o valor da previsão anual e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019. O principal benefício deste mecanismo consiste em prover ao gestor de Municciamento da OM um intervalo de confiança da previsão anual, que pode ser útil na definição de uma margem de segurança do item no estoque, que, conforme Santos e Oliveira (2016), possa viabilizar o equilíbrio entre as quantidades armazenadas e consumidas na OM ao longo do ano.

No caso em lide, a previsão alternativa apresentou um desvio de 2,16%, valor este ligeiramente inferior ao desvio de 4,03% da previsão anual resultante do somatório das previsões mensais.

Tabela 26 – Previsão acumulada para 2019 – frango – HN – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
100.129	102.293,94	96.510,20	108.077,70	2,16%


Fonte: O autor, 2021.

Os resultados obtidos pelo processo de previsão de demanda no Hospital Naval demonstraram características que atendem ao requerido pelo ETP, que prevê a utilização de métodos quantitativos para as quantidades estimadas de itens de estoque a serem adquiridas com base no histórico de consumo (ALVES, 2021; BRASIL, 2021; ME, 2020).

3.5 Análise da previsão de consumo de frango em um navio

Para consecução do processo de previsão de demanda de frango, em Kg, em um navio da MB, foram coletados no sistema Quaestor os dados de consumo do item no período de 2015 a 2019. Os dados do período de 2015 a 2018 foram utilizados para os ajustes dos modelos preditivos, enquanto os dados do exercício de 2019, para a comparação com os dados obtidos através das previsões. Na Figura 51 pode-se observar a série temporal de consumo de frango no navio analisado, durante o período de 2015 a 2018.

Figura 51 – Série do consumo de frango em um navio – 2015 a 2018



Fonte: O autor, 2021.


Cabe destacar, que devido ao processo de implantação do Quaestor nos navios da MB (BRASIL, 2015), não foi possível obter uma série temporal de consumo de itens de estoque de alimentos maior do que o período de 2015 a 2019, haja vista ainda a necessidade de alternância

de utilização do Quaestor com o sistema MUNIC, quando da necessidade de realização de longas viagens.

De forma preliminar, observa-se uma variação nas quantidades e períodos de consumo do peito de frango, em Kg, no navio. Além disso, na Figura 51, não é possível constatar uma tendência nítida, apenas o fato de que no exercício de 2018 houve um aumento no nível de consumo do item quando comparado aos demais anos da série.

Para uma melhor análise, foi gerada na decomposição da série, disposta na Figura 52, em que são evidenciadas as componentes não observáveis da série em questão, quais sejam: tendência, sazonalidade e irregular.

Figura 52 – Decomposição da série de consumo de frango no navio



Fonte: O autor, 2021.

Desta forma, verificou-se na Figura 52 uma tendência de aumento do consumo do peito de frango no navio analisado. Adicionalmente pode ser observado uma sazonalidade nos meses de abril e agosto, indicando uma elevação no consumo do item nesses meses. Quando analisado o histórico de consumo dos itens em um navio, os gestores devem levar em consideração no planejamento dos níveis de estoque a necessidade de realização de viagens no decorrer do ano, que demandam longos períodos no mar, e por consequência, uma elevação no consumo de alimentos por parte das tripulações. A seguir, serão realizados os processos de previsão de demanda com base no método aditivo de Holt-Winters e na metodologia Box & Jenkins.

3.5.1 Previsão de consumo de frango em um navio baseada no método de Holt-Winters

Após a análise exploratória dos dados, referentes à série temporal de consumo de peito de frango em um navio da MB, foi iniciado o processo de previsão do item para o ano de 2019. Nesse escopo, foram obtidas as constantes de alisamento do modelo, expostas na Tabela 27.

Tabela 27 – Parâmetros de suavização


Item	alfa	beta	gama
Frango	0.1747	0	0.7651

Fonte: O autor, 2021.

Na Tabela 27 foi possível observar que o parâmetro de suavização α apresentou valor próximo à zero, indicando que as estimativas para a componente nível possuem peso maior para as observações mais antigas. O parâmetro β apresentou valor igual à zero, demonstrando que, assim como no caso da componente nível, as estimativas da componente de tendência também indicaram maiores pesos para as observações mais antigas. Já o parâmetro γ apresentou um valor próximo à um, indicando que as estimativas da componente de sazonalidade atribuem pesos maiores às observações mais recentes.

A seguir, na Figura 53 apresenta-se a série temporal do consumo de peito de frango (linha em preto) e as estimativas mensais (linha em vermelho) resultantes do ajuste do modelo de Holt-Winters.

Figura 53 – Ajuste sazonal do consumo de frango no navio



Fonte: O autor, 2021.

Após a realização do ajuste do modelo preditivo de Holt-Winters, foi possível obter previsões até 12 passos à frente, referentes ao consumo de peito de frango, em Kg, para o ano de 2019 em um navio da MB.

As previsões obtidas encontram-se na Tabela 28, que dispõe dos valores observados em 2019, extraídos do Quaestor, bem como dos valores previstos mensalmente, além dos desvios relativos.

O desvio relativo referente ao total do consumo anual apresentou valor de 27,13%. A incerteza da rotina de um navio da MB pode refletir no consumo dos gêneros alimentícios, bem como nos resultados das previsões. Em alguns casos, quando em viagens para localidades geográficas com poucas opções de abastecimento do estoque, como nos casos das regiões ribeirinhas, a alternância dos tipos de cardápios é comum nos navios, podendo comprometer o comportamento do ciclo de consumo de um determinado item, e por conseguinte as previsões das quantidades de consumo. Tal fato pode ser exemplificado no caso do navio analisado, em que os desvios relativos nos meses apresentaram altos valores em alguns casos do ano de 2019.

Tabela 28 – Previsão de consumo para 2019
– frango – navio – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	45	67,86	50,80%
Fev	62	68,29	10,15%
Mar	114	82,80	27,37%
Abr	107	111,56	4,26%
Mai	49	95,60	95,10%
Jun	75	92,40	23,20%
Jul	31	126,97	300,09%
Ago	56	140,92	151,64%
Set	50	64,17	28,34%
Out	145	110,54	23,77%
Nov	64	65,01	1,57%
Dez	87	99,04	13,84%
TOTAL	885	1.125,16	27,13%

Fonte: O autor, 2021.

Adicionalmente, na Tabela 29, apresentam-se as métricas MAPE, MAD e RMSE referentes aos valores mensais.


Tabela 29 – Métricas de desempenho

MAPE	MAD	RMSE
61,64%	30,96	42,80

Fonte: O autor, 2021.

Numa perspectiva anual, verificou-se que o montante total de consumo previsto, apresentou um desvio relativo de 27,13% total efetivamente consumido. Ressalta-se ainda que a gestão do Municíamento de um navio encontra diferentes cenários logísticos ao longo de suas viagens. Ainda que o estoque de alimentos esteja abastecido em sua capacidade máxima, em certos casos ocorrem limitações de fornecimento em determinadas regiões, afetando assim o histórico de consumo de determinados itens. Desta forma, tendo em vista que desde o mês de janeiro de 2020 os navios passaram a ser apoiados pelos Centros de Intendência da Marinha (CeIM) nos processos de aquisições, os gestores dos CeIM deverão considerar estas variações quando da elaboração dos processos licitatórios de gêneros alimentícios. Em seguida, na Figura 54, tem-se a visualização das previsões mensais (linha em azul) na sequência dos valores observados e acompanhadas dos intervalos de previsão com 95% de confiança.

Figura 54 – Previsão de consumo de frango em um navio – 2019 - HW



Fonte: O autor, 2021.

A previsão de consumo anual do frango, em Kg, no navio, apresentou valor que pode ser utilizado no ETP de aquisição do item, embora tenha apresentado um desvio relativo de 27,13%. A seguir foi executado o processo de previsão alternativo que possibilita a obtenção do valor acumulado previsto para o ano de 2019 com o seu respectivo de intervalo de confiança. A aplicação do método de Holt-Winters na série de consumo mensal acumulado de 12 meses produziu a previsão de consumo anual na Tabela 30.

Tabela 30 – Previsão acumulada para 2019 – frango – navio – HW

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
885	1.094,20	923,20	1.265,20	23,63%

Fonte: O autor, 2021.

Conforme visualizado na Tabela 30, neste caso a previsão pontual obtida pelo procedimento alternativo apresentou um desvio relativo ligeiramente menor do que o somatório das previsões mensais. A previsão anual resultante da soma das previsões mensais (1.125,16 Kg) e previsão dada pelo acumulado de 12 meses em dezembro (1.094,20 Kg) são superiores ao consumo de frango no ano de 2019 no navio (885 Kg), o que indica que as previsões cobririam com folga a demanda do item naquele exercício. Desta forma, os resultados mostraram-se aceitáveis para inclusão na elaboração dos ETP.

Ballou (2006) alerta quanto à elaboração de previsões de demanda para itens de estoque que apresentem muitas variações em sua série histórica, indicando que as previsões por meio dos métodos estatísticos podem ser comprometidas devido às grandes flutuações no consumo.

Após o estabelecimento da nova estrutura de aquisição de gêneros alimentícios para os navios, que passou a vigorar em 01 de janeiro de 2020, cabe aos CeIM a tarefa de elaborar os ETP referentes aos processos licitatórios dos itens de estoque de alimentos dos navios.

Com isto, o método alternativo de previsão do valor acumulado pode vir a se tornar um mecanismo eficiente para a elaboração dos Termos de Referência, uma vez que, a licitação abarcará a quantidade total de um determinado item para distribuição aos navios de um determinado Distrito Naval, além de otimizar os cálculos das quantidades a serem inseridas nos processos licitatórios.

Ressalta-se ainda que os processos licitatórios realizados na modalidade pregão eletrônico para as aquisições dos alimentos, geram uma ata de registro de preços (ARP) que possui a validade de um ano. Neste documento, os CeIM não possuem a obrigatoriedade de aquisição das quantidades totais dispostas no contrato, embora os fornecedores tenham o compromisso de efetuar os respectivos fornecimentos, quando solicitados (BRASIL, 2021).

Sendo assim, o intervalo de confiança e o contraste entre as previsões anuais nas Tabelas 28 e 30 fornecem subsídios para a definição de uma margem de segurança da previsão. Tal constatação torna-se ainda mais relevante nos casos dos navios, que por possuírem características operativas distintas de uma OM sediada em terra, aumentam ainda mais o grau de incerteza do consumo de alimentos, cabendo aos CeIM elaborarem planejamentos que amortecem as flutuações de consumo, o que neste caso, podem ser utilizados os intervalos de confiança como possíveis quantidades a serem inseridas na ARP.

3.5.2 Previsão de consumo de frango em um navio baseada na metodologia Box & Jenkins

A OM analisada trata-se de um navio da MB, que por sua vez, possui peculiaridades distintas de uma OM sediada em terra, sendo a de maior destaque a possibilidade de se deslocar em viagens operativas da Força. As viagens realizadas alteram os níveis de consumo dos itens de estoque de alimentos, uma vez que, o navio permanece em longos períodos navegando. Além disso, as viagens nem sempre ocorrem nos mesmos períodos dos anos, alterando assim as características de sazonalidade do consumo.

Na sequência, foi utilizada a função *auto.arima* do *software* R para se obter o modelo proposto para a obtenção das previsões pela metodologia Box & Jenkins. Na Figura 55 estão dispostos os resultados iniciais referentes ao modelo sugerido.

Figura 55 – Ordem do modelo SARIMA – frango – navio

```
> modelo=auto.arima(serie)
> summary(modelo)
Series: serie
ARIMA(0,1,1)(1,0,0)[12]

Coefficients:
      mal      sar1
    -0.8127  0.3552
s.e.    0.1058  0.1704

sigma^2 estimated as 500.2:  log likelihood=-213.04
AIC=432.08  AICc=432.64  BIC=437.63
```

Fonte: O autor, 2021.

Conforme indicado na Figura 55, a função *auto.arima* sugere um modelo SARIMA $(0,1,1) \times (1,0,0)_{12}$, i.e., o modelo proposto possui um coeficiente de média móvel de ordem 1 (*ma1* ou $q=1$) na componente não sazonal e um coeficiente autorregressivo de ordem 1 na componente sazonal (*sar1* ou $P=1$). Além disso, foi tomada a primeira diferença na componente não sazonal ($d=1$). Adicionalmente, conforme indicado pelos *p-values* na Figura 56, os coeficientes estimados são estatisticamente significativos ao nível de 5%.


Figura 56 – *p-values* dos coeficientes estimados – frango – navio

```
> pvalor(modelo)
      mal      sar1
9.966847e-10 4.284050e-02
```

Fonte: O autor, 2021.

Na Figura 57, o histograma e o *qq-plot* dos resíduos e, sobretudo, o *p-value* do teste de Shapiro-Wilk (0,35143) apontam para a validade da premissa de normalidade assumida no modelo SARIMA (0,1,1)x(1,0,0)₁₂.


Figura 57 – Gráficos de normalidade dos resíduos do modelo – frango – navio



Fonte: O autor, 2021.

Complementarmente, o gráfico da FAC dos resíduos na Figura 58 e os *p-values* resultantes do teste de Ljung-Box (todos acima de 5%) na Figura 59 indicam a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo. Portanto, as considerações acima permitem concluir que o modelo SARIMA(0,1,1)x(1,0,0)₁₂ é adequado (BARROS *et al.*, 2020) e mostra-se apto à realização das previsões mensais do consumo de frango no navio.

Figura 58 – FAC dos resíduos do modelo – frango – navio



Fonte: O autor, 2021.

Figura 59 – *p-values* do Teste Ljung-Box – frango – navio

lags	statistic	p-value
1	0.8023345	0.4055944
2	1.4571740	0.5134865
3	1.7199947	0.6303696
4	1.9257162	0.7682318
5	3.0086472	0.7032967
6	4.6813262	0.5834166
7	5.5354870	0.6063936
8	5.8021331	0.6723277
9	7.7955972	0.5484515
10	7.8679704	0.6163836
11	7.9252389	0.7012987
12	7.9272607	0.7662338
13	8.0404692	0.8161838
14	9.8428812	0.7402597
15	9.8669258	0.7982018
16	10.2429045	0.8231768
17	10.6415100	0.8411588
18	10.6436043	0.8851149
19	10.7516469	0.9070929
20	10.7678281	0.9380619
21	12.4903667	0.9000999
22	12.8868536	0.9130869
23	13.6259725	0.9260739
24	13.9794757	0.9350649

Fonte: O autor, 2021.

Assim, foram geradas as previsões de consumo de frango para o exercício de 2019 a partir do modelo ajustado. Na Tabela 31 apresentam-se os valores mensais observados em 2019, os valores previstos, bem como os respectivos desvios relativos.

Tabela 31 – Previsão de consumo para 2019 – frango – navio – BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	45	64,55	43,44%
Fev	62	68,46	10,42%
Mar	114	72,01	36,83%
Abr	107	83,73	21,75%
Mai	49	79,47	62,18%
Jun	75	79,48	5,97%
Jul	31	94,40	204,5%
Ago	56	101,85	81,88%
Set	50	67,74	35,48%
Out	145	90,84	37,35%
Nov	64	68,81	7,52%
Dez	87	80,53	7,44%
TOTAL	885	951,87	7,56%

Fonte: O autor, 2021.

Conforme ilustrado na Tabela 31, a previsão anual para 2019, definida pelo valor total acumulado previsto de consumo de frango no navio analisado, excedeu ao total observado em

7,56%. A seguir, na Tabela 32 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.

Tabela 32 – Métricas de desempenho

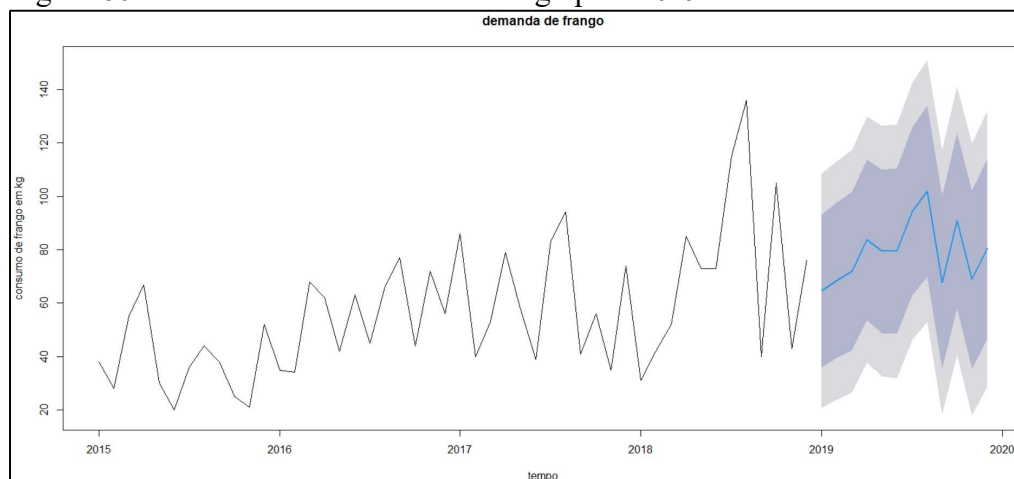
MAPE	MAD	RMSE
46,23%	26,55	33,06

Fonte: O autor, 2021.

Os resultados obtidos para as previsões mensais de consumo do peito de frango no navio analisado apresentaram desvios relativos considerados altos, demonstrando a dificuldade em se obter previsões neste tipo de OM, o que se alinha ao mencionado por Ballou (2006), quando relata a complexidade em se obter bons resultados preditivos por meio de métodos quantitativos quando a série temporal apresenta grandes variações em suas observações. Entretanto, no que concerne à elaboração do ETP, a previsão acumulada apresentou um resultado satisfatório, excedendo ao total consumido em 7,56%.

Na Figura 60 apresentam-se as previsões mensais para o ano de 2019 (linha em azul), acompanhadas dos respectivos intervalos com confiança de 80% e 95% (áreas em cores cinza escuro e claro), e precedidas pelos dados do período 2015-2018 (linha em preto).

Figura 60 – Previsão de consumo de frango para 2019 - navio - BJ




Fonte: O autor, 2021.

Como sugestão de alternativa para obtenção da previsão anual do item, efetuou-se a previsão do acumulado de 12 meses para dezembro do ano de 2019. Neste caso, a função *auto.arima* identificou o modelo SARIMA (0,1,0)x(1,0,0). Além disso, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem marginalmente ao pressuposto

de normalidade, conforme disposto na Figura 61, em que o p -value resultante do teste de Shapiro-Wilk foi da ordem de 41,297%, portanto, não significativo ao nível de 10%.

Figura 61 – QQ -plot dos resíduos do modelo SARIMA – frango – navio



Fonte: O autor, 2021.

Na Tabela 33 são disponibilizados o valor da previsão anual e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019. A principal virtude desta alternativa consiste em prover um intervalo de confiança da previsão anual e que pode ser útil na definição de uma margem de segurança. Adicionalmente, neste caso, a previsão alternativa apresentou um desvio de 27,80%, valor superior ao desvio de 7,56% da previsão anual resultante do somatório das previsões mensais.

Tabela 33 – Previsão acumulada para 2019 – frango – navio – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
885	1.122,68	1.020,36	1.224,99	27,80%

Fonte: O autor, 2021.

Com isto, as previsões obtidas pela metodologia Box & Jenkins para o navio analisado, não apresentaram boa acurácia quando das estimativas de consumo mensais. O resultado de previsão anual que apresentou menor desvio foi o obtido pelo somatório das previsões mensais.


3.6 Análise da previsão de consumo de banana em uma OM do CFN

A análise da previsão de consumo de banana, em Kg, foi realizada com dados referentes ao Município de uma OM do CFN. Cabe ressaltar que o referido tipo de OM possui como uma de suas principais características a realização diária do Treinamento Físico Militar (TFM), o que reflete em um consumo quase que diário de frutas no café da manhã dos militares.

A banana foi classificada como a fruta com maior custo em 2019, com base no consumo anual do item na MB e nos critérios de apuração de custos para itens de estoque oriundos do processo de convergência da contabilidade pública aos padrões internacionais contábeis.

A Figura 62 expõe a série de consumo de banana no período de 2014 a 2018 na OM analisada.

Figura 62 – Série temporal de consumo de banana – 2014 a 2018




Fonte: O autor, 2021.

Visualmente a série temporal de consumo de banana na OM analisada expõe uma tendência de aumento do consumo da referida fruta nos últimos meses. Além disso, observa-se preliminarmente uma sazonalidade aditiva, tendo em vista a constância da amplitude dos valores mensais ao longo dos anos expostos na série, o que possibilita a aplicação do método aditivo de Holt-Winters no primeiro processo preditivo a ser realizado.

Com o propósito de se obter uma visualização gráfica mais detalhada, foi realizada a decomposição da série em suas componentes não observáveis, i.e., tendência, sazonalidade e irregular, conforme disposto na Figura 63.

Figura 63 – Decomposição da série temporal de consumo de banana



Fonte: O autor, 2021.

A Figura 63 demonstra que a tendência de consumo de banana na OM vem apresentando uma elevação nos últimos meses, após uma redução do patamar de consumo no exercício de 2016. A componente sazonal indica certa constância de consumo do item ao longo do ano, não sendo identificado claramente períodos sazonais.

3.7.1 Previsão de consumo de banana baseada no método de Holt-Winters

Após a análise exploratória dos dados do processo de previsão de consumo de banana em uma OM do CFN, foi iniciado o ajuste do modelo preditivo baseado no método aditivo de Holt-Winters. As constantes de alisamento ou parâmetros de suavização resultantes são apresentadas na Tabela 34.

Tabela 34 – Parâmetros de suavização - banana

Item	alfa	beta	gama
banana	0,4102	0,0164	0,6623


Fonte: O autor, 2021.

Após a obtenção dos parâmetros de suavização, observou-se que os coeficientes α e β apresentaram valores próximos à zero, o que indica que o modelo considera os dados mais antigos da série temporal com pesos maiores nas equações de nível e tendência.

Adicionalmente, o coeficiente γ , atrelado à componente de sazonalidade, apresentou valor igual a 0,6623, implicando em um peso maior para os dados mais recentes nesta componente, quando do ajuste do modelo preditivo.

A seguir, na Figura 64 apresenta-se a série temporal do consumo de banana (em preto) e as estimativas mensais (em vermelho) resultantes do ajuste do modelo de Holt-Winters.

Figura 64 – Ajuste sazonal do consumo de banana



Fonte: O autor, 2021.

Após a realização do ajuste do modelo, foi possível então obter previsões até 12 passos à frente, referentes ao consumo de banana, mês a mês, para o exercício de 2019 em uma OM do CFN.

A pesquisa realizada por Reis *et al.* (2019) trouxe aspectos sobre a previsão de demanda de itens de estoque de alimentos em um mercado de bairro. Na ocasião foram analisados itens de hortifruti e suas demandas correspondentes. Os autores relataram no estudo a dificuldade de se obter previsões para estes tipos de gêneros alimentícios devido à flutuabilidade de demanda que estes apresentam. Adicionalmente, os autores alertam para as dificuldades de realização de previsão de demanda para os hortifrutis (frutas, legumes e hortaliças), uma vez que estes alimentos apresentam grande risco de deterioração e quando não consumidos, dificilmente podem ser reaproveitados, e por isso, os gestores devem buscar estabelecer em seus planejamentos, quantidades que satisfaçam os clientes de forma que as perdas sejam minimizadas para a instituição.

Em paralelo, Ballou (2006) e Ghiani, Laporte e Musmanno (2004) alertam quanto ao risco de obtenção de resultados com pouca acurácia para séries temporais que disponham de demandas que não apresentem certa regularidade, o que torna ineficaz a aplicação de métodos

quantitativos para a obtenção de previsões. Na Tabela 35 estão dispostos os valores observados de consumo do item, mês a mês, no ano de 2019, bem como os valores previstos pelo método de Holt-Winters. Na parte inferior da Tabela 35 destaca-se que o desvio relativo de 20,49% entre o consumo total anual observado e o consumo anual previsto.

Tabela 35 – Previsão de consumo para 2019
– banana – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	152	392,60	158,29%
Fev	217	296,80	36,77%
Mar	370	357,90	3,27%
Abr	841	349,77	58,41%
Mai	608	395,34	34,98%
Jun	342	414,25	21,13%
Jul	369	289,93	21,43%
Ago	464	370,00	20,26%
Set	491	372,88	24,06%
Out	425	323,21	23,95%
Nov	632	418,24	33,82%
Dez	440	273,43	37,86%
TOTAL	5.351	4.254,35	20,49%

Fonte: O autor, 2021.

Adicionalmente, na Tabela 36, apresentam-se as métricas MAPE, MAD e RMSE referentes aos valores mensais.

Tabela 36 – Métricas de desempenho

MAPE	MAD	RMSE
39,52%	156,83	197,69

Fonte: O autor, 2021.


Numa perspectiva anual, verificou-se que o montante total de consumo previsto, aproximou-se em 79,51% do total efetivamente consumido.

Releva mencionar que o consumo de frutas em uma OM apresenta certa dificuldade de identificação de um comportamento padronizado da demanda, uma vez que este tipo de gênero alimentício sofre constantes alterações em seus preços, demandando aos gestores o reequilíbrio dos valores contratuais das atas de registro de preços (ARP).

Além disso, ressalta-se que um tipo de fruta pode ser substituído por um outro tipo que venha atender às exigências nutricionais fixadas nas dietas dos militares, acarretando assim em uma variação dos tipos de frutas consumidas ao longo do ano.

Adicionalmente, na Figura 65 tem-se a visualização gráfica das previsões mensais (linha em azul) na sequência dos valores observados e acompanhadas dos intervalos de previsão com 95% de confiança que indicam as magnitudes das incertezas.

Figura 65 – Previsão de consumo de banana para 2019 - HW



Fonte: O autor, 2021.

Nesse sentido, visando a obtenção de um intervalo de confiança associado à previsão anual, pode-se adotar um procedimento alternativo que consiste em calcular a previsão do consumo acumulado nos últimos 12 meses para dezembro de 2019 (previsão de 12 passos à frente), a partir da série mensal do consumo acumulado de 12 meses.

A aplicação do método de Holt-Winters na série de consumo mensal acumulado de 12 meses produziu a previsão de consumo anual da banana na Tabela 37.

Tabela 37 – Previsão acumulada para 2019 – banana – HW

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
5.351	7.992,35	5.073,99	10.910,70	49,36%

Fonte: O autor, 2021.

Para a elaboração do PAR da OM e do ETP que comporá o processo licitatório de aquisição dos hortifrutis, o gestor poderá adotar para o planejamento da OM a quantidade obtida na previsão acumulada, que embora tenha excedido à quantidade observada de consumo em 2019 em 49,36%, poderá amortecer as incertezas de demanda deste tipo de gênero alimentício,

que tem apresentado uma tendência de aumento do consumo nos últimos meses na OM analisada. Além disso, cabe destacar que a quantidade disposta na ARP, conforme previsto no art. 83 da Lei nº 14.133/2021, não gera obrigatoriedade de compra por parte do órgão gerenciador da ata, embora a justificativa da previsão de consumo deva constar no ETP (BRASIL, 2021).

3.7.2 Previsão de consumo de banana baseada na metodologia Box & Jenkins

Conforme análise gráfica a partir da decomposição da série temporal de consumo de banana (Figura 63), em uma OM do CFN da MB, foi possível constatar que a série não possui uma sazonalidade definida explicitamente, indicando apenas uma redução do consumo nos meses de fevereiro.

Para a obtenção das previsões por meio da metodologia Box & Jenkins, utilizou-se a função *auto.arima* do *software* R, cujos resultados referentes à identificação do modelo estão dispostos na Figura 66.

Figura 66 – Ordem do modelo ARIMA - banana

```
> modelo=auto.arima(serie)
> summary(modelo)
Series: serie
ARIMA(0,1,1)

Coefficients:
          mal
          -0.6236
s.e.      0.0977


sigma^2 estimated as 19166:  log likelihood=-374.36
AIC=752.71  AICc=752.92  BIC=756.87
```

Fonte: O autor, 2021.

A função *auto.arima* sugeriu um modelo ARIMA (0,1,1), i.e., o modelo proposto possui um coeficiente de média móvel de ordem 1 (*ma1* ou $q=1$) na componente não sazonal e estabeleceu uma diferenciação de ordem 1 ($d=1$) para remoção da tendência. O *p-value* do coeficiente estimado foi $3,1287e^{-08}$, ou seja, o coeficiente é estatisticamente significativo ao nível de 5%.

Em seguida, na Figura 67, o histograma e *qq-plot* dos resíduos e, sobretudo, o *p-value* do teste Shapiro-Wilk (0,5249) apontam para a validade da premissa de normalidade assumida no modelo ARIMA (0,1,1).


Figura 67 – Gráficos da normalidade dos resíduos do modelo - banana



Fonte: O autor, 2021.

O gráfico da FAC dos resíduos na Figura 68 indicam a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo.

Figura 68 – FAC dos resíduos do modelo - banana



Fonte: O autor, 2021.

Complementarmente, foi realizado o teste Ljung-Box (ou Portmanteau) (BARROS *et al.*, 2020), cujos *p-values* (todos acima de 5%) na Figura 69, ratificam a ausência de qualquer estrutura de autocorrelação entre os resíduos, concluindo assim a fase de verificação do modelo no ciclo iterativo proposto por Morettin e Toloí (2018), quando da realização do processo preditivo através da abordagem Box & Jenkins.

Após esta verificação, o modelo poderá ser empregado na fase de obtenção das previsões.

Figura 69 – *p-values* do Teste
Ljung-Box - banana

lags	statistic	p-value
1	0.002281392	0.9600400
2	0.118375151	0.9530470
3	0.131717423	0.9880120
4	0.164292718	0.9950050
5	0.272021620	0.9980020
6	1.516593715	0.9620380
7	1.758316740	0.9730270
8	2.721359096	0.9440559
9	4.487789577	0.8691309
10	4.673997714	0.9100899
11	4.968632524	0.9310689
12	5.926886689	0.9130869
13	5.967448935	0.9460539
14	6.142610395	0.9640360
15	7.399555390	0.9400599
16	8.540274506	0.9150849
17	13.080423040	0.7032967
18	14.659549633	0.6443556
19	14.661124741	0.7092907
20	15.126100528	0.7382617
21	15.379392812	0.7712288
22	15.379985807	0.8061938
23	15.531579214	0.8351648
24	16.183071342	0.8531469

Fonte: O autor, 2021.

Portanto, com base nos resultados estatísticos obtidos, as considerações anteriores permitem concluir que o modelo ARIMA (0,1,1) é adequado (BARROS *et al.*, 2020) e mostra-se apto à realização das previsões mensais do consumo de banana.

Sendo assim, foram geradas as previsões de consumo de banana, em Kg, para o exercício de 2019 a partir do modelo ajustado. Na Tabela 38 apresentam-se os valores mensais observados em 2019, os valores previstos para aquele exercício, bem como os respectivos desvios relativos.

Tabela 38 – Previsão de consumo para 2019
– banana – BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	152	451,59	197,10%
Fev	217	451,59	108,11%
Mar	370	451,59	22,05%
Abr	841	451,59	46,30%
Mai	608	451,59	25,73%
Jun	342	451,59	32,05%
Jul	369	451,59	22,38%
Ago	464	451,59	2,67%
Set	491	451,59	8,03%
Out	425	451,59	6,26%
Nov	632	451,59	28,55%
Dez	440	451,59	2,63%
TOTAL	5.351	5.419,08	1,27%

Fonte: O autor, 2021.

Conforme disposto na Tabela 38, a previsão anual para 2019, definida pelo valor total acumulado previsto de consumo de banana na OM do CFN analisada, excedeu ao total observado em 1,27%. A seguir, na Tabela 39 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.


Tabela 39 – Métricas de desempenho

MAPE	MAD	RMSE
41,82%	135,35	178,30

Fonte: O autor, 2021.

Na Figura 70 apresentam-se as previsões mensais para o exercício de 2019 (linha em azul), acompanhadas dos respectivos intervalos de confiança de 80% e 95% (áreas em cores cinza escuro e claro), e precedidas pelos dados de consumo do item no período de 2014 à 2018 (linha em preto).


Figura 70 – Previsão de consumo de banana para 2019 – BJ



Fonte: O autor, 2021.

Como sugestão de alternativa para a obtenção da previsão anual do item, efetuou-se a previsão do acumulado de 12 meses para dezembro do ano de 2019. Neste caso, a função *auto.arima* identificou o modelo SARIMA (0,2,1)x(0,0,1). Além disso, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem ao pressuposto de normalidade, conforme disposto na Figura 71, em que o *p-value* resultante do teste de Shapiro-Wilk foi da ordem de 26,73%, portanto, não significativo aos níveis usuais de significância.

Figura 71 – *QQ-plot* dos resíduos do modelo SARIMA – banana



Fonte: O autor, 2021.

Na Tabela 40 são disponibilizados o valor da previsão anual e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019. A principal virtude desta alternativa consiste em prover um intervalo de confiança da previsão anual e que pode ser útil na definição de uma margem de segurança, inclusive para este tipo de gênero alimentício, que, conforme Reis *et al.* (2019), costuma apresentar demandas irregulares, dificultando assim o estabelecimento das previsões.

Neste caso, a previsão alternativa apresentou um desvio de 18,55%, valor este superior ao desvio de 1,27% da previsão anual resultante do somatório das previsões mensais.

Tabela 40 – Previsão acumulada para 2019 – banana – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
5.351	6.343,82	3.963,22	8.724,43	18,55%

Fonte: O autor, 2021.


Considerando as incertezas da demanda dos hortifrutigranjeiros, as quantidades a serem inseridas no PAR da OM e no ETP que comporá o processo licitatório de aquisição do item poderão adotar medidas que abarquem uma margem de segurança, haja vista que a ata de registro de preços não gera obrigatoriedade da compra da totalidade dos itens (BRASIL, 2021).

3.7 Análise da previsão de consumo de açúcar em uma Base da MB

Inicialmente foram obtidos os dados de consumo de açúcar, em Kg, em uma Base da Marinha do Brasil durante o período de 2014 a 2018, de forma que fosse possível ajustar os modelos preditivos de Holt-Winters e Box & Jenkins. Os dados de consumo do item durante o ano de 2019 foram utilizados para a comparação com os valores das previsões obtidas.

A referida Base tem o propósito de apoiar as demais OM sediadas no mesmo Complexo Naval, no que tange aos serviços gerais, dentre eles a execução da gestão de estoque de alimentos, que prevê o fornecimento de alimentação diária aos militares e servidores civis que trabalham naquela localidade.

Figura 72 – Série temporal de consumo de açúcar – 2014 a 2018




Fonte: O autor, 2021

Na Figura 72 pode-se observar que a série de consumo de açúcar apresenta uma redução dos níveis de consumo ao longo dos últimos anos, atingindo certa estabilidade no nível de consumo até o final do exercício de 2018. É possível identificar reduções de consumo nos meses de dezembro, mês este peculiar ao gozo de férias por parte dos militares e período de recesso administrativo na esfera pública, o que reduz a quantidade de militares trabalhando nas OM e o consumo dos gêneros alimentícios.

A decomposição da série em suas componentes não observáveis (Figura 73), i.e., tendência, sazonalidade e irregular, possibilita a realização de uma análise exploratória mais detalhada a respeito do consumo de açúcar na OM em questão.

Figura 73 – Decomposição da série temporal de consumo de açúcar



Fonte: O autor, 2021.

Conforme exposto na Figura 73, observa-se que desde o mês de setembro de 2016 o patamar de consumo do item apresentou certa estabilidade após um movimento de redução iniciado no ano de 2014. Em uma medida preliminar e conservadora, o gestor na Base poderá manter os níveis de estoque dos últimos meses, tendo em vista a tendência de estabilidade no nível de consumo. No que concerne à sazonalidade, observa-se uma queda do nível de consumo no mês de dezembro.

3.7.1 Previsão de consumo de açúcar baseada no método de Holt-Winters

Após análise exploratória dos dados do processo de previsão de consumo de açúcar, em Kg, em uma Base da MB, bem como a identificação de características da série temporal em estudo, foi iniciado o ajuste do modelo preditivo baseado no método aditivo de Holt-Winters. As constantes de alisamento ou parâmetros de suavização resultantes são apresentadas na Tabela 41.

Tabela 41 – Parâmetros de suavização – açúcar

Item	alfa	beta	gama
açúcar	0,0183	1	0,8578


Fonte: O autor, 2021.

Após a obtenção dos parâmetros de suavização, observou-se que o coeficiente α apresentou valor próximo à zero, o que indica que o modelo considera os dados mais antigos da série temporal com pesos maiores na equação de nível.

Adicionalmente, os coeficientes β e γ , atrelados às componentes de tendência e sazonalidade, apresentaram valores iguais a 1 e 0,8578, respectivamente, implicando em um peso maior para os dados mais recentes nestas componentes, quando do ajuste do modelo preditivo.

A seguir, na Figura 74, apresenta-se a série temporal do consumo de açúcar (em preto) e as estimativas mensais (em vermelho) resultantes do ajuste do modelo de Holt-Winters.

Figura 74 – Ajuste sazonal do consumo de açúcar



Fonte: O autor, 2021.

Após a realização do ajuste do modelo, foi possível então obter previsões até 12 passos à frente, referentes ao consumo de açúcar, mês a mês, para o ano de 2019 em uma Base da MB.

Cabe destacar que o açúcar foi um dos gêneros alimentícios classificados como de maiores custos no exercício de 2019, dentre os gêneros secos consumidos pelas OM da MB. De certa forma, os gêneros secos que são utilizados praticamente de forma diária na elaboração das refeições da MB tendem a apresentar uma série temporal com níveis de consumo mais constantes, o que facilita o ajuste de modelos preditivos baseados em métodos quantitativos como o de Holt-Winters.

Entretanto, cabe aos gestores analisarem as tendências e sazonalidades de consumo para que não haja a falta dos itens em períodos específicos, bem como não se imobilize capital desnecessariamente. Com isto, a análise exploratória realizada preliminarmente pode se tornar um recurso gerencial útil à gestão de estoques de alimentos das OM da MB, antes mesmo da realização das previsões.

Em seguida, na Tabela 42 são apresentadas as previsões mensais, juntamente com os valores observados.

Tabela 42 – Previsão de consumo para 2019
– açúcar – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	590	670,49	13,64%
Fev	581	692,81	19,24%
Mar	598	706,40	18,13%
Abr	717	682,95	4,75%
Mai	610	609,45	0,1%
Jun	618	565,05	8,57%
Jul	577	587,10	1,75%
Ago	633	524,62	17,12%
Set	649	640,35	1,33%
Out	574	598,66	4,30%
Nov	614	616,71	0,44%
Dez	503	480,53	4,47%
TOTAL	7.264	7.375,12	1,53%

Fonte: O autor, 2021.

Na parte inferior da Tabela 42 destacam-se os valores totais anuais de consumo de açúcar para o exercício de 2019, com um desvio relativo da ordem de 1,53% entre o consumo anual observado e o consumo anual previsto.

Adicionalmente, na Tabela 43, apresentam-se as métricas MAPE, MAD e RMSE referentes aos valores mensais de consumo.

Tabela 43 – Métricas de desempenho


MAPE	MAD	RMSE
7,82%	47,10	63,07

Fonte: O autor, 2021.

Numa perspectiva anual, verificou-se que o montante total de consumo previsto excedeu em 1,53% o total efetivamente consumido naquele no ano de 2019. Após a obtenção deste resultado, foi possível verificar que assim como os desvios relativos entre a previsão anual e o efetivo consumo do arroz (5,36%) e feijão (0,15%), o açúcar apresentou um desvio relativo considerado baixo por meio da previsão mensal de Holt-Winters.

Adicionalmente, na Figura 75 tem-se a visualização das previsões mensais (linha em azul) na sequência dos valores observados e acompanhadas dos intervalos de previsão com 95% de confiança que indicam as magnitudes das incertezas.

Figura 75 – Previsão de consumo de açúcar para 2019 - HW



Fonte: O autor, 2021.

A previsão do consumo anual demonstrou atender aos preceitos de elaboração do ETP, no que concerne à elaboração das estimativas das quantidades de consumo, conforme previsto na IN nº 40/2020 e na Lei nº 14.133/2021 (BRASIL, 2021; ME, 2020). Além disso, as previsões mensais apresentaram baixos desvios relativos e podem ser úteis ao gestor ao longo do ano no que tange ao ressuprimento do item no estoque da OM analisada. Os valores estimados podem subsidiar as solicitações das quantidades de açúcar junto ao fornecedor, respeitando o saldo disponível na ata de registro de preços (ARP) elaborada com as estimativas de consumo obtidas através dos métodos quantitativos de previsão utilizados no ETP.

Contudo, visando a obtenção do intervalo de confiança associado à previsão anual, pode-se adotar um procedimento alternativo que consiste em calcular a previsão do consumo acumulado nos últimos 12 meses para dezembro de 2019 (previsão 12 passos à frente), a partir da série mensal do consumo acumulado de 12 meses.

A aplicação do método de Holt-Winters na série de consumo mensal acumulado de 12 meses produziu a previsão de consumo anual na Tabela 44.

Tabela 44 – Previsão acumulada para 2019 – açúcar – HW

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
7.264	7.470,55	6.266,34	8.674,76	2,84%

Fonte: O autor, 2021

Conforme visualizado na Tabela 44, neste caso a previsão pontual obtida pelo procedimento alternativo apresentou um desvio relativo ligeiramente maior do que o somatório das previsões mensais. As previsões anuais resultantes da soma das previsões mensais (7.374,12

Kg) e do procedimento alternativo (7.470,55 Kg) são superiores ao consumo do açúcar na Base em 2019 (7.264 Kg), o que indica que ambos os resultados cobrem com folga a demanda anual.

3.7.2 Previsão de consumo de açúcar baseada na metodologia Box & Jenkins

Na Figura 76 é possível verificar que a função *auto.arima* sugeriu um modelo SARIMA $(0,1,1) \times (1,0,0)_{12}$, i.e., o modelo proposto possui um coeficiente de média móvel de ordem 1 (*ma1* ou $q=1$) na componente não sazonal e um coeficiente autorregressivo de ordem 1 na componente sazonal (*sar1* ou $P=1$). Além disso, foi sugerido tomar a primeira diferença ($d=1$) na componente não sazonal da série. Conforme indicado na Figura 76, os coeficientes estimados são estatisticamente significativos ao nível de 5%.

Figura 76 – Ordem do modelo SARIMA - açúcar

```
> modelo=auto.arima(serie)
> summary(modelo)
Series: serie
ARIMA(0,1,1)(1,0,0)[12]

Coefficients:
      mal      sar1
    -0.7873  0.3779
s.e.   0.0889  0.1551

sigma^2 estimated as 10984:  log likelihood=-358.56
AIC=723.12  AICc=723.56  BIC=729.35
```

Fonte: O autor, 2021.


Figura 77 – *p-values* dos coeficientes estimados – açúcar

```
> pvalor(modelo)
      mal      sar1
2.667592e-12 1.800384e-02
> |
```

Fonte: O autor, 2021.

Na Figura 78, o histograma e o *qq-plot* dos resíduos e, sobretudo, o *p-value* do teste de Shapiro-Wilk (0,024306), apontam para a validade, ao nível de significância de 1%, da premissa de normalidade assumida no modelo SARIMA $(0,1,1) \times (1,0,0)_{12}$.


Figura 78 – Gráficos da normalidade dos resíduos do modelo – açúcar



Fonte: O autor, 2021.

Complementarmente, o gráfico da FAC dos na Figura 79 e os p -values do teste Ljung-Box (todos acima de 5%) na Figura 80, indicam a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo.

Figura 79 – FAC dos resíduos do modelo – açúcar



Fonte: O autor, 2021.

Figura 80 – p -values do Teste Ljung-Box – açúcar

lags	statistic	p-value
1	5.459337e-04	0.9770230
2	8.934493e-02	0.9670330
3	6.992373e-01	0.8821179
4	2.243017e+00	0.7132867
5	2.510830e+00	0.7882118
6	2.604734e+00	0.8661339
7	3.396237e+00	0.8451548
8	4.106268e+00	0.8401598
9	8.905159e+00	0.4315684
10	9.440582e+00	0.4575425
11	9.460211e+00	0.5454545
12	1.218957e+01	0.4075924
13	1.408028e+01	0.3546454
14	1.434757e+01	0.3956044
15	1.533708e+01	0.4165834
16	1.727381e+01	0.3506494
17	1.741777e+01	0.4065934
18	1.954362e+01	0.3566434
19	2.272952e+01	0.2577423
20	2.280842e+01	0.3006993
21	2.463394e+01	0.2687313
22	2.773526e+01	0.2027972
23	2.847237e+01	0.2267732
24	2.853353e+01	0.2597403

Fonte: O autor, 2021.

Portanto, as considerações acerca da análise dos resíduos permitem concluir que o modelo SARIMA(0,1,1)x(1,0,0)₁₂ é adequado (BARROS *et al.*, 2020; MORETTIN; TOLOI, 2018) e mostra-se apto à realização das previsões mensais do consumo de açúcar.

Assim, foram geradas as previsões de consumo de açúcar para o exercício de 2019 a partir do modelo ajustado. Na Tabela 45 apresentam-se os valores mensais observados em 2019, os valores previstos, bem como os respectivos desvios relativos.

Tabela 45 – Previsão de consumo para 2019
– açúcar – BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	590	604,12	2,39%
Fev	581	620,75	6,84%
Mar	598	623,01	4,18%
Abr	717	620,37	13,48%
Mai	610	595,43	2,39%
Jun	618	579,94	6,16%
Jul	577	587,87	1,88%
Ago	633	562,18	11,19%
Set	649	609,79	6,04%
Out	574	592,79	3,27%
Nov	614	602,23	1,92%
Dez	503	551,22	9,59%
TOTAL	7.264	7.149,70	1,57%

Fonte: O autor, 2021.

Conforme indicado na Tabela 45, a previsão anual para 2019, definida pelo valor acumulado previsto de consumo de açúcar na OM analisada, aproximou-se do total observado em 98,43%. A seguir, na Tabela 46 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.

Tabela 46 – Métricas de desempenho


MAPE	MAD	RMSE
5,78%	35,65	43,68

Fonte: O autor, 2021.

Os resultados encontrados foram considerados satisfatórios para o planejamento das compras de itens de estoque de alimentos da OM, podendo os resultados serem inseridos no PAR da OM (ou plano anual de contratações) e no ETP do processo licitatório de gêneros alimentícios.

Na Figura 81 apresentam-se as previsões mensais para o exercício de 2019 (linha em azul), acompanhadas dos respectivos intervalos de confiança de 80% e 95% (áreas em cores cinza escuro e claro) que refletem a magnitude das incertezas (POCHIRAJU; SESHADRI, 2019), e precedidas pelos dados do período de 2014-2018 (linha em preto).


Figura 81 – Previsão de consumo de açúcar para 2019 – BJ



Fonte: O autor, 2021.

Cabe destacar que, o total acumulado anual obtido pela metodologia Box & Jenkins (7.149,70 Kg) foi menor do que o efetivamente consumido no ano de 2019 (7.264 Kg), diferentemente do resultado apresentado pelo método de Holt-Winters (7.375,12 Kg), que inclui uma margem de segurança para possíveis flutuações da demanda. Como sugestão de alternativa para a obtenção da previsão anual do item, efetuou-se a previsão do acumulado de 12 meses para dezembro do ano de 2019. Neste caso, a função *auto.arima* identificou o modelo SARIMA(0,2,1)x(0,0,1).

Figura 82 – *QQ-plot* dos resíduos do modelo SARIMA - açúcar



Fonte: O autor, 2021.

Além disso, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem ao pressuposto de normalidade, conforme disposto na Figura 82, em que o *p-value* resultante do teste de Shapiro-Wilk foi da ordem de 5,51%, portanto, não significativo ao nível de 5%. Com isto, foi gerado o valor da previsão anual e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019, conforme exposto na Tabela 47.

Tabela 47 – Previsão acumulada para 2019 – açúcar – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
7.264	7.031,40	5.916,08	8.146,72	3,20%


Fonte: O autor, 2021

Neste caso, a previsão alternativa apresentou uma aproximação de 96,80%, valor este inferior aos 98,43% obtidos pela previsão anual resultante do somatório das previsões mensais. Sendo assim, ambos os resultados se mostraram satisfatórios para a inserção nos documentos de planejamento e controle do estoque de alimentos da OM.

3.8 Análise da previsão de consumo de batata em uma OM do CFN

Inicialmente foi realizada uma análise exploratória dos dados a partir dos dados da série temporal de consumo de batata, em Kg, no período de 2014 a 2018.

Figura 83 – Série temporal de consumo de batata - 2014 a 2018




Fonte: O autor, 2021

A partir do gráfico disposto na Figura 83, foi possível observar preliminarmente certa variação no consumo do item ao longo dos meses, comportamento este típico de séries de itens de hortifruti, conforme mencionado por Reis *et al.* (2019).

Para uma observação com maior detalhamento, foi gerada a decomposição da referida série temporal de consumo, exposta na Figura 84.

Figura 84 – Decomposição da série temporal do consumo de batata



Fonte: O autor, 2021

A Figura 84 demonstra uma oscilação dos níveis de consumo da batata ao longo do período analisado, fato este evidenciado pela componente de tendência, que após apresentar um crescimento do consumo entre 2016 e 2017, a partir de julho de 2017 iniciou um movimento de redução do consumo até atingir certa estabilidade no exercício de 2018. A sazonalidade apresenta reduções no mês de dezembro, devido ao período de férias de muitos militares e do período de recesso administrativo no setor público, conforme identificado nas análises anteriores.

3.8.1 Previsão de consumo de batata baseada no método de Holt-Winters

Após a análise exploratória dos dados, a partir da obtenção do gráfico da série de consumo de batata na OM analisada e sua respectiva decomposição, foram obtidas as constantes de alisamento ou parâmetros de suavização para o ajuste do modelo de Holt-Winters, conforme dispostos na Tabela 48.


Tabela 48 – Parâmetros de suavização – batata

Item	alfa	beta	gama
batata	0,4108	0,0188	0,2997

Fonte: O autor, 2021.

Após a obtenção dos parâmetros de suavização, observou-se que os coeficientes α , β e γ apresentaram valores mais próximos à zero, o que indica que o modelo considera os dados mais antigos da série temporal com pesos maiores nas equações de nível, tendência e sazonalidade, quando do ajuste do modelo preditivo. A seguir, na Figura 85 apresenta-se a série temporal do consumo de batata (em preto) e as estimativas mensais (em vermelho) resultantes do ajuste do modelo de Holt-Winters.

Figura 85 – Ajuste sazonal do consumo de batata



Fonte: O autor, 2021

Assim como na análise realizada para a obtenção das previsões de consumo de banana em uma OM do CFN, a batata pertence à classe de gêneros alimentícios que engloba os hortifrutigranjeiros.

De acordo com Reis *et al.* (2019), os processos de previsões desta classe de gênero alimentício podem apresentar certa dificuldade devido ao fato de a demanda para estes alimentos não serem costumeiramente regulares.

Após a realização do ajuste do modelo, foi possível então obter previsões até 12 passos à frente, referentes ao consumo de batata, mês a mês, para o exercício de 2019 em uma OM do CFN, conforme exposto na Tabela 49.

Tabela 49 – Previsão de consumo para 2019
– batata – HW

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	381	406,32	6,65%
Fev	213	259,68	21,92%
Mar	335	328,41	1,97%
Abr	337	352,96	4,74%
Mai	367	407,80	11,12%
Jun	362	322,63	10,88%
Jul	178	255,07	43,30%
Ago	412	402,05	2,42%
Set	242	275,53	13,86%
Out	406	396,06	2,45%
Nov	248	235,87	4,89%
Dez	210	293,27	39,65%
TOTAL	3.691	3.935,65	6,63%

Fonte: O autor, 2021

Na Tabela 49 estão dispostos os valores observados mensalmente referentes ao consumo de batata, em Kg, em 2019, bem como suas respectivas previsões para aquele ano, seguidas dos desvios relativos mensais. Na parte inferior da Tabela 49 destacam-se os valores totais anuais de consumo de batata para 2019, com um desvio relativo da ordem de 6,63% entre o consumo anual observado e o consumo anual previsto.

Adicionalmente, na Tabela 50, apresentam-se as métricas MAPE, MAD e RMSE referentes aos valores mensais.

Tabela 50 – Métricas de desempenho


Item	MAPE	MAD	RMSE
Batata	13,65%	33,38	41,51

Fonte: O autor, 2021.

Numa perspectiva anual, verificou-se que o montante de consumo previsto excedeu em 6,63% o total efetivamente consumido, mostrando ser uma performance passível de inclusão na elaboração do PAR da OM, bem como nos aspectos gerenciais do planejamento da OM, sobretudo na elaboração do ETP.

Na Figura 86 apresenta-se a visualização das previsões mensais (linha em azul) na sequência dos valores observados e acompanhadas dos intervalos de previsão com 95% de confiança, que indicam as magnitudes das incertezas.

Figura 86 – Previsão de consumo de batata para 2019 – HW



Fonte: O autor, 2021

De acordo com Reis *et al.* (2019), a previsão de itens de hortifruti, como no caso em lide, exige dos gestores uma atenção maior, devido às incertezas das demandas destes tipos de gêneros alimentícios. A previsão obtida pode ser empregada como subsídio ao planejamento e controle da OM analisada, bem como no planejamento do processo de aquisições dos itens.

Como medida a reduzir os riscos de compras em quantidades maiores do que as necessárias, ou em quantidades menores do que as necessidades da OM, foi utilizado o procedimento alternativo que consiste em calcular a previsão do consumo acumulado nos últimos 12 meses para dezembro de 2019 (previsão 12 passos à frente), a partir da série mensal do consumo acumulado de 12 meses. Este procedimento possibilita a obtenção de um intervalo de confiança associado à previsão anual, conforme exposto na Tabela 51 a seguir.

Tabela 51 – Previsão acumulada para 2019 – batata – HW

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
3.691	3.474,52	2.377,15	4.571,89	5,87%

Fonte: O autor, 2021

Conforme visualizado na Tabela 51, neste caso a previsão pontual obtida pelo procedimento alternativo apresentou um desvio relativo ligeiramente menor do que o somatório das previsões mensais. Entretanto, a previsão anual resultante da soma das previsões mensais (3.935,65 Kg) é superior ao consumo efetivo da batata em 2019 (3.691 Kg), enquanto a previsão dada pelo acumulado de 12 meses em dezembro (3.474,52 Kg) foi menor do que a demanda anual.

Tais resultados demonstram ser prudente a adoção de um intervalo de confiança na elaboração do ETP, de forma que a inclusão do limite superior obtido possa abarcar a

flutuabilidade da demanda ao longo do ano. Quando se executa o processo de planejamento de aquisição de itens hortifrutí, esta medida pode ser ainda mais útil, de forma que o risco de desabastecimento destes itens seja mitigado.

3.8.2 Previsão de consumo de batata baseada na metodologia Box & Jenkins

Inicialmente foi utilizada a função *auto.arima* do *software* R para a obtenção da sugestão de um modelo que possa ser empregado na obtenção das previsões de consumo de batata, em Kg, conforme exposto na Figura 87.

Figura 87 – Ordem do modelo ARIMA - batata

```
> modelo=auto.arima(serie)
> summary(modelo)
Series: serie
ARIMA(1,0,1) with non-zero mean

Coefficients:
      ar1      ma1      mean
    0.8255 -0.5646 365.8937
s.e. 0.1377  0.1706  35.4169

sigma^2 estimated as 13211:  log likelihood=-368.4
AIC=744.79  AICc=745.52  BIC=753.17
```

Fonte: O autor, 2021

Conforme indicado na Figura 87, a função *auto.arima* sugeriu um modelo ARIMA (1,0,1), i.e., o modelo proposto possui um coeficiente autorregressivo (*ar1* ou $p=1$) e um coeficiente de média móvel (*ma1* ou $q=1$), ambos de ordem 1 na componente não sazonal do modelo.

Em seguida, foram obtidos os *p-values* dos coeficientes do modelo, expostos na Figura 88 a seguir.

Figura 88 – *p-values* dos coeficientes estimados
– batata


```
> pvalor(modelo)
      ar1      ma1  intercept
1.395552e-07 1.611166e-03 9.156457e-15
> |
```

Fonte: O autor, 2021

Conforme indicado na Figura 88, os *p-values* dos coeficientes estimados são estatisticamente significativos ao nível de 5%.

Em seguida, foram executados procedimentos inerentes à análise dos resíduos, de forma a verificar a validade do modelo obtido para o fornecimento das previsões. Na Figura 89 estão dispostos o histograma e o *qq-plot* dos resíduos.

Figura 89 – Gráficos da normalidade dos resíduos do modelo - batata




Fonte: O autor, 2021

Na Figura 89, o histograma e o *qq-plot* dos resíduos e, sobretudo, o *p-value* do teste de Shapiro-Wilk (0,2644) apontam para a validade da premissa de normalidade assumida no modelo ARIMA (1,0,1)₁₂.

Complementarmente, o gráfico da FAC dos resíduos na Figura 90 e os *p-values* resultantes do teste de Ljung-Box (todos acima de 5%) na Figura 91, indicam a ausência de qualquer estrutura de autocorrelação entre os resíduos do modelo.

Figura 90 – FAC dos resíduos do modelo - batata



Fonte: O autor, 2021

Figura 91 – *p-values* do Teste
Ljung-Box – batata

lags	statistic	p-value
1	0.3163716	0.6103896
2	0.3167883	0.8791209
3	0.3167981	0.9670330
4	1.4756117	0.8511489
5	2.3241175	0.8271728
6	9.0956310	0.1598402
7	9.1008667	0.2527473
8	9.8346888	0.2817183
9	9.8378835	0.3506494
10	12.1310748	0.2627373
11	13.5781588	0.2497502
12	14.0786384	0.2937063
13	14.1767271	0.3526474
14	14.5661040	0.3846154
15	15.2769597	0.4285714
16	15.4258175	0.4745255
17	17.5976702	0.3946054
18	17.7907446	0.4455544
19	17.8617027	0.5064935
20	17.8916655	0.5674326
21	17.9227833	0.6153846
22	18.4113363	0.6433566
23	19.0530345	0.6553447
24	22.1385296	0.5534466

Fonte: O autor, 2021

Portanto, com base nas considerações referentes à análise dos resíduos, é possível concluir que o modelo ARIMA (1,0,1)₁₂ é adequado e mostra-se apto à realização das previsões mensais do consumo de batata. Assim, foram geradas as previsões de consumo de batata para o exercício de 2019 a partir do modelo ajustado. Na Tabela 52 apresentam-se os valores mensais observados em 2019, os valores previstos, bem como os respectivos desvios relativos.

Tabela 52 – Previsão de consumo para 2019
– batata – BJ

Mês	Observado (Kg)	Previsto (Kg)	Desvio Relativo
Jan	381	361,21	5,19%
Fev	213	362,03	69,97%
Mar	335	362,70	8,27%
Abr	337	363,26	7,79%
Mai	367	363,72	0,89%
Jun	362	364,01	0,56%
Jul	178	364,41	104,72%
Ago	412	364,67	11,49%
Set	242	364,88	50,78%
Out	406	365,06	10,08%
Nov	248	365,21	47,26%
Dez	210	365,33	73,97%
TOTAL	3.691	4.366,49	18,30%

Fonte: O autor, 2021

Conforme ilustrado na Tabela 52, a previsão anual para 2019, definida pelo valor total acumulado previsto de consumo de batata na OM analisada, excedeu ao total observado em 18,30%. A seguir, na Tabela 53 apresentam-se as métricas de desempenho tradicionalmente consideradas na avaliação das previsões mensais.

Tabela 53 – Métricas de desempenho


Item	MAPE	MAD	RMSE
Batata	32,58%	74,85	98,19

Fonte: O autor, 2021.

Desta forma as previsões mensais obtidas pela metodologia Box & Jenkins apresentam-se como mais uma opção de subsídio ao planejamento e controle da gestão de estoque de alimentos da OM, embora os resultados mensais do método de Holt-Winters tenham apresentado melhor performance quando comparados com os do método ARIMA. Esta constatação pode ser evidenciada quando comparados os resultados das métricas de desempenho nas Tabelas 50 e 53.

Na Figura 92 apresentam-se as previsões mensais para o ano de 2019 (linha em azul), acompanhadas dos respectivos intervalos de confiança de 80% e 95% (áreas em cores cinza escuro e claro), e precedidas pelos dados do período de 2014-2018 (linha em preto).

Figura 92 – Previsão do consumo de batata para 2019 – BJ



Fonte: O autor, 2021

Cabe destacar que os resultados obtidos pelo método de Holt-Winters apresentaram maior aproximação do consumo efetivo no ano de 2019. O total acumulado obtido pelo somatório das previsões mensais oriundas do método de Holt-Winters (3.935,65 Kg) foi maior

do que o efetivamente consumido no ano de 2019 (3.691 Kg), assim como o resultado obtido pela metodologia Box & Jenkins (4.366,49 Kg).

Como sugestão de alternativa para a obtenção da previsão anual do item, efetuou-se a previsão do acumulado de 12 meses para dezembro de 2019. Neste caso, a função *auto.arima* identificou o modelo SARIMA (2,0,1)x(1,0,0), conforme exposto na Figura 93.

Figura 93 – Ordem do modelo SARIMA - batata

```
> modelo=auto.arima(serie12)
> summary(modelo)
Series: serie12
ARIMA(2,0,1)(1,0,0)[12] with non-zero mean


Coefficients:
      ar1      ar2      ma1      sar1      mean
      1.8261  -0.8652  -0.5148  -0.5292  4167.5024
s.e.    0.1190   0.1156   0.2115   0.1417   171.5527

sigma^2 estimated as 15326:  log likelihood=-307.15
AIC=626.3   AICc=628.3   BIC=637.65
```

Fonte: O autor, 2021

Adicionalmente, foi verificado que os resíduos não apresentam estrutura de autocorrelação e atendem ao pressuposto de normalidade, conforme disposto na Figura 94, em que o *p-value* resultante do teste de Shapiro-Wilk foi da ordem de 67,129%, portanto, não significativo ao nível de 10%.

Figura 94 – *QQ-plot* dos resíduos do modelo – batata



Fonte: O autor, 2021

Na Tabela 54 são disponibilizados o valor da previsão anual e seu respectivo intervalo de confiança, obtidos por meio da previsão do acumulado de 12 meses para dezembro de 2019.

Adicionalmente, neste caso, a previsão alternativa apresentou um desvio de 21,44% da previsão anual resultante do somatório das previsões mensais.

Tabela 54 – Previsão acumulada para 2019 – batata – BJ

Observado (Kg)	Previsão (Kg)	Limite Inferior	Limite Superior	Desvio Relativo
3.691	4.482,20	3.737,48	5.226,91	21,44%

Fonte: O autor, 2021

No caso em lide, o limite inferior do intervalo de confiança poderia ser um parâmetro a ser adotado pelo gestor quando da elaboração do PAR da OM e do ETP do processo licitatório de aquisição do item. O emprego do intervalo de confiança no planejamento do processo de aquisição permite ao setor contábil de alimentos da OM dispor de um plano de contingência caso ocorram grandes variações na demanda, sem a necessidade de realização de aditivos ou novos processos licitatórios.

3.9 Análise conjunta dos resultados das previsões

A Tabela 55 apresenta os resultados das previsões para o consumo anual de seis itens de estoque de alimentos consumidos na MB, analisados em sete processos de previsão nesta pesquisa. Foram utilizadas duas abordagens, Holt-Winters (HW) e Box & Jenkins (BJ), com o emprego de duas técnicas em cada uma, o que gerou as previsões de consumo mensais (HW1 e BJ1) e do total acumulado para 12 meses (HW2 e BJ2). Portanto, obteve-se o conjunto com 28 resultados preditivos apresentados na Tabela 55 a seguir.

Tabela 55 – Resultados das previsões de consumo dos gêneros alimentícios

Item	Observado (Kg)	HW1 (Kg)	Desvio	HW2 (Kg)	Desvio	BJ1 (Kg)	Desvio	BJ2 (Kg)	Desvio
arroz	20.199	19.115	5,36%	21.568	6,78%	23.809	17,87%	22.997	13,85%
feijão	2.751	2.746	0,15%	2.811	2,21%	2.624	4,58%	2.995,78	8,90%
frango1	100.129	106.715	6,58%	102.154	2,02%	104.165	4,03%	102.293	2,16%
frango2	885	1.125	27,13%	1.094	23,63%	951	7,56%	1.122	27,80%
banana	5.351	4.254	20,49%	7.992	49,36%	5.419	1,27%	6.343	18,55%
açúcar	7.264	7.375	1,53%	7.470	2,84%	7.149	1,57%	7.031	3,20%
batata	3.691	3.935	6,63%	3.474	5,87%	4.366	18,30%	4.482	21,44%

Fonte: O autor, 2021

Em termos gerais, o método de Box & Jenkins (BJ1) apresentou uma excelente performance, pois apresentou a menor mediana para o desvio relativo (4,58%), com desvios menores que 5% em quatro itens e o menor desvio máximo (18,3%).

Cabe destacar que em todas as análises realizadas, as previsões de consumo de frango em um navio (frango2) apresentaram desvios relativos em relação ao consumo efetivo no ano de 2019 considerados grandes. Entretanto, dentre os quatro métodos utilizados na referida análise, a abordagem Box & Jenkins para previsões mensais foi a que apresentou melhor resultado, com um desvio anual relativo da ordem de 7,56%. A série de consumo de gêneros alimentícios em navios apresenta uma maior incerteza em função da rotina deste tipo de OM, que efetua diversos deslocamentos no território nacional, encontrado cenários logísticos distintos em cada região, o que dificulta a constância de fornecimento de determinados itens, bem como a regularidade de consumo destes.

Na análise preditiva do consumo de banana em uma OM do CFN, foi verificado que, assim como no caso da série de consumo de frango no navio, a metodologia que apresentou melhor performance foi a Box & Jenkins para o consumo mensal, em que o desvio anual relativo em comparação ao total consumido em 2019, foi de 1,27%.

As análises preditivas de consumo de itens de hortifruti, conforme Reis *et al.* (2019), apresentam certa complexidade devido às incertezas da demanda destes tipos de alimentos. Desta forma, dentre as análises realizadas, as duas séries temporais com maiores variações em seus consumos (frango 2 e banana) apresentaram melhores previsões a partir da metodologia Box & Jenkins para o consumo mensal.

Já a aplicação do método Box & Jenkins na série acumulada de 12 meses (BJ2) apresentou os piores resultados, haja vista os desvios relativos elevados (mediana igual a 13,70%), com quatro previsões apresentando os maiores desvios relativos.

Adicionalmente, os resultados mostram que as previsões de consumo para os gêneros secos apresentaram melhores resultados a partir do método de Holt-Winters (HW1 e HW2). Estes resultados se alinham aos achados de pesquisa encontrados nos estudos de Santos e Alves (2017) e Veiga *et al.* (2014), em que as previsões de demanda de gêneros alimentícios realizadas pelos mencionados pesquisadores, apresentaram melhores acurácias com o método de Holt-Winters quando comparado com outros métodos. Ressalta-se que o método de Holt-Winters possui uma capacidade de ajuste automático quando da inserção de novos dados, diferentemente dos modelos Box & Jenkins.

Os resultados na Tabela 55 mostram que o método de Holt-Winters acumulado de 12 meses (HW2) resultou em mediana dos desvios relativos da ordem de 5,87%, com 3 previsões

apresentando desvios relativos menores que 5%. Adicionalmente, o método HW2 resultou na previsão com o maior desvio relativo (49,36%). Apesar disso, o método HW2 superou a acurácia do método de Box & Jenkins (BJ1) em quatro dos sete itens: arroz, feijão, frango e batata, o que qualifica o método HW2 como um bom concorrente do método BJ1.

Adicionalmente, dos sete resultados obtidos com o referido método, seis apresentaram valores superiores às quantidades, em Kg, efetivamente consumidas no ano de 2019. Salienta-se que embora os resultados oriundos do método de Holt-Winters mensal (HW1) tenham apresentado desvios relativos baixos em alguns itens, as quantidades previstas indicaram em duas análises, valores menores do que os efetivamente consumidos.

Destaca-se ainda que os métodos de previsão do acumulado de 12 meses (HW2 e BJ2) permitem aos gestores utilizarem valores contidos nos intervalos de confiança fornecidos pelos mecanismos, possibilitando assim uma margem de segurança frente às incertezas das demandas, além de mitigar riscos de desabastecimento ou de realização de aditivos dos contratos.

A partir do julgamento humano dos gestores, os limites dos intervalos de confiança das previsões do acumulado de 12 meses podem se tornar bons mecanismos de planejamento, podendo ser, portanto, inseridos nas atas de registro de preços (ARP) dos processos de aquisição dos gêneros alimentícios, haja vista a não obrigatoriedade de aquisição dos itens em sua totalidade, conforme previsto na lei de licitações e contratos, além de atender aos requisitos metodológicos inerentes ao cálculo das quantidades a partir de métodos quantitativos.

Os resultados encontrados a partir dos processos de previsão são considerados satisfatórios às atividades do Município da Marinha do Brasil, sobretudo nos aspectos de planejamento e controle dos estoques de alimentos, incluindo as tarefas inerentes aos processos licitatórios das aquisições destes itens e na elaboração dos ETP. Assim, a partir das considerações acima sugere-se a ordem de adoção na execução das previsões: método acumulado de Holt-Winters (HW2), método de Holt-Winters mensal (HW1), metodologia Box & Jenkins mensal (BJ1), e por fim, a metodologia Box & Jenkins acumulada (BJ2).

O mencionado ranqueamento se alinha ao mencionado por Petropoulos, Wang e Disney (2019), que destacam que o método de Holt-Winters pode proporcionar melhores resultados quando comparados com métodos mais complexos. Entretanto, cabe ressaltar que para séries que apresentaram maior irregularidade nas demandas, os autores sugerem a adoção da metodologia Box & Jenkins mensal (BJ1) como primeira opção de adoção pelos gestores.

3.10 Análise das combinações das previsões

Após a realização das análises das previsões mensais de consumo de alimentos nas OM da MB, obtidas pelo método de Holt-Winters (HW1) e pela metodologia Box & Jenkins (BJ1), foram efetuadas as combinações dos referidos resultados com base no método de Regressão Linear por Mínimos Quadrados Ordinários (OLS) (C1) e no método de combinação convexa (C2).

No que concerne às previsões de consumo mensais, a Tabela 56 apresenta os resultados totais previstos e o erro médio mensal das previsões obtidas por cada método, expresso pelos valores dos MAPE.

Tabela 56 – Previsões mensais e MAPE das combinações

Item	Observado (Kg)	HW1 (Kg)	MAPE	BJ1 (Kg)	MAPE	C1 (Kg)	MAPE	C2 (Kg)	MAPE
arroz	20.199	19.115	10,03%	23.809	21,01%	19.590	7,48%	19.115	10,03%
feijão	2.751	2.746	2,67%	2.624	10,10%	2.636	9,12%	2.653	8,18%
frango1	100.129	106.715	19,62%	104.165	23,47%	107.443	22,31%	105.829	20,57%
frango2	885	1.125	61,64%	951	46,23%	976	47,32%	1.125	61,64%
banana	5.351	4.254	39,52%	5.419	41,82%	4.911	38,15%	5.419	41,82%
açúcar	7.264	7.375	7,82%	7.149	5,78%	7.470	6,87%	7.174	5,91%
batata	3.691	3.935	13,65%	4.366	32,58%	4.028	22,69%	4.140	21,52%

Fonte: O autor, 2022

Desta forma, foi possível observar que os métodos de combinação de previsões possibilitaram uma melhora do MAPE no processo de previsão de consumo de arroz, cujo valor obtido pelo método de combinação C1 (7,48%) apresentou uma redução de 2,55% em relação ao MAPE do método HW1 (10,03%). Adicionalmente, o processo de previsão de consumo de banana também indicou uma redução do MAPE por meio do método de combinação C1, que passou a apresentar um percentual de 38,15%, configurando uma redução de 1,37% quando comparado ao MAPE do método HW1 (39,52%).

Entretanto, conforme relatado por Nowotarski e Weron (2016), as combinações não garantem um melhor resultado de previsão, mas sim uma opção adicional de modelo que pode proporcionar melhores resultados, como ocorrido nos processos de previsão de consumo de arroz e banana. De uma forma geral, o método de combinação C1 apresentou uma performance superior ao método C2 nos casos em que a combinação de previsões foi efetiva, i.e., reduziu o MAPE da previsão.

Na sequência, a Tabela 57 apresenta os resultados previstos de consumo anual dos gêneros alimentícios nas OM da MB analisadas, bem como os respectivos desvios anuais frente aos valores observados, resultantes dos métodos HW1, BJ1, C1 e C2.

Tabela 57 – Previsões anuais e desvios das combinações

Item	Observado (Kg)	HW1 (Kg)	Desvio	BJ1 (Kg)	Desvio	C1 (Kg)	Desvio	C2 (Kg)	Desvio
arroz	20.199	19.115	5,36%	23.809	17,87%	19.590	3,01%	19.115	5,36%
feijão	2.751	2.746	0,15%	2.624	4,58%	2.636	4,16%	2.653	3,56%
frango1	100.129	106.715	6,58%	104.165	4,03%	107.443	7,30%	105.829	5,69%
frango2	885	1.125	27,13%	951	7,56%	976	10,33%	1.125	27,14%
banana	5.351	4.254	20,49%	5.419	1,27%	4.911	8,21%	5.419	1,27%
açúcar	7.264	7.375	1,53%	7.149	1,57%	7.470	2,85%	7.174	1,23%
batata	3.691	3.935	6,63%	4.366	18,30%	4.028	9,13%	4.140	12,17%

Fonte: O autor, 2022

No que tange aos desvios anuais, foi possível identificar uma redução no desvio anual do processo de previsão de consumo do arroz, cujo menor valor indicava 5,36% (HW1) e passou para 3,01% (C1), e no processo de previsão de consumo de açúcar, que passou de 1,53% (HW1) para 1,23% (C2). Em paralelo, o processo de previsão de consumo de banana apresentou pelo método BJ1, um desvio anual de 1,27%, valor este que se manteve através do método de combinação C2. Cabe destacar que a combinação C1 apresenta a menor média e a menor amplitude dos desvios.

Quando analisadas as medianas dos desvios relativos anuais segundo cada método empregado, observou-se que o método HW1 apresentou uma mediana de 6,58%, enquanto no método BJ1 a mediana foi da ordem de 4,58%. Diante destes resultados, pode-se concluir que o método BJ1 apresentou um desempenho superior ao HW1. No que se refere às previsões combinadas, a combinação foi efetiva em reduzir o MAPE em apenas dois casos: o método C1 melhorou a previsão do arroz e o método C2 melhorou a previsão do consumo de açúcar.

Cabe ressaltar que as combinações podem sugerir aos gestores que compõem a estrutura do Município da MB uma alternativa de realização de previsões que, conforme Weiss, Raviv e Roetzer (2018), possibilita uma maior segurança frente aos riscos envolvidos nos processos preditivos. Entretanto, cabe salientar que, nem sempre os resultados combinados resultarão em melhores previsões quando comparadas aos resultados obtidos pelos métodos individuais.

Desta forma, foi possível avaliar que as combinações de previsões podem contribuir para a melhora de alguns processos de previsões mensais de consumo de alimentos nas OM da

MB, além de se apresentar como mais uma alternativa de modelo preditivo no processo de planejamento e controle dos estoques de alimentos das OM, sobretudo na elaboração dos Estudos Técnicos Preliminares (ETP).

3.11 Análise da aplicação das previsões no SCM

Após a realização dos processos preditivos dos itens de estoque de alimentos de diferentes tipos de OM da MB, foi possível obter as previsões anuais de consumo dos referidos itens. Conforme disposto nos regramentos de apuração de custos para itens de estoque, oriundos do processo de convergência da contabilidade pública aos padrões contábeis internacionais, o custo passa a ser registrado no momento do consumo, e não no momento de sua aquisição. Desta forma as previsões obtidas pelo mecanismo utilizado nesta pesquisa podem ser empregadas como parâmetros para a projeção dos custos no processo de planejamento do exercício financeiro subsequente de cada Organização Militar da MB.

A partir das informações geradas, os gestores poderão realizar uma comparação das previsões de custos dos principais gêneros alimentícios utilizados rotineiramente nos cardápios das OM, e confrontá-los com a estimativa orçamentária para o exercício subsequente, proporcionando assim às OM, subsídios gerenciais a serem utilizados nas tomadas de decisão inerentes ao planejamento do Município para o ano subsequente.

Em paralelo, as informações voltadas às estimativas de custos, obtidas a partir das previsões de consumo, podem ser utilizadas como parâmetros para as atividades desenvolvidas pelo Sistema de Custos da Marinha (SCM), que possui dentre as suas tarefas a responsabilidade de realizar o acompanhamento das diretrizes do Sistema de Informações de Custos do Governo Federal (SIC), bem como alimentar o referido sistema com as devidas informações contábeis inerentes à Força.

Cabe destacar que as projeções de custos dos alimentos refletem uma estimativa anual de consumo de cada um, carecendo desta forma, da alocação de parcela destes custos aos Centros de Custos da MB, que objetivam medir os custos de determinadas atividades desenvolvidas pela instituição, ou seja, em que contexto eles são utilizados.

Quando da necessidade de realização de cortes de custos, os gestores poderão se valer das informações geradas pelo mecanismo empregado nesta pesquisa, avaliando assim a essencialidade e materialidade de cada item para as refeições dos militares e suas respectivas

perspectivas de custos anuais, podendo assim contribuir para a definição de prioridades das aquisições de alimentos e de um equilíbrio dos custos frente ao orçamento previsto para a alimentação.

Adicionalmente, as informações de custo podem ser empregadas em análises comparativas pela Alta Administração Naval, como por exemplo quando se deseja avaliar o desenvolvimento de uma determinada atividade executada por OM de mesma natureza (MACHADO; HOLANDA, 2010). A partir destas análises, poderá ser realizada a identificação das oportunidades de melhorias no Municíamento de cada OM, além da possibilidade de utilização das projeções em indicadores de desempenho que possam contribuir para a racionalização do emprego dos recursos públicos alocados à instituição.

Cabe destacar que as informações contábeis de consumo de alimentos registradas no SIAFI, não apresentam um detalhamento dos itens que foram consumidos em um determinado exercício, dispondo apenas do saldo contábil das saídas do estoque de uma determinada OM na subconta contábil de alimentos. Esta configuração não permite aos gestores identificarem quais itens são responsáveis pelas maiores parcelas de custos dos alimentos. Sendo assim, a análise individualizada das projeções de consumo e de custos dos principais gêneros alimentícios utilizados pela MB, podem possibilitar o fornecimento de informações mais detalhadas para as tomadas de decisão.

Além disso, as projeções de custos apresentam-se como informações gerenciais que podem auxiliar na elaboração dos orçamentos, confrontando o previsto de consumo com as necessidades de recursos para suportá-los ao longo do exercício financeiro, permitindo aos gestores analisarem com maior precisão as decisões de alocações de recursos.

CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo avaliar como o processo de previsão de demanda, baseado em métodos estatísticos, pode contribuir para o planejamento e controle do Municciamento das OM da MB. Com isto, a pesquisa teve um caráter descritivo e uma abordagem quantitativa.

Desta forma, foram realizados sete processos preditivos com base em duas abordagens, o método de Holt-Winters e a metodologia Box & Jenkins, técnicas estas difundidas no campo dos estudos das previsões nas áreas econômica, financeira e orçamentária, as quais a contabilidade pública atua harmonicamente gerando informações gerenciais para as tomadas de decisão em diferentes níveis organizacionais. Posteriormente, utilizou-se os resultados obtidos por cada método e realizou-se a combinação das previsões, o que viabilizou analisar a possibilidade de melhoria da acurácia de alguns resultados.

Para a realização dos processos preditivos, realizou-se uma classificação dos itens de estoque de alimentos cadastrados no banco de dados do sistema Quaestor, de forma que fosse possível elencar os gêneros alimentícios com maior representatividade nos estoques de alimentos das OM. Os itens foram divididos em três categorias: gêneros secos; gêneros refrigerados e hortifrutigranjeiros. Desta forma, realizou-se a identificação dos itens com maiores custos no exercício de 2019, baseado nos novos padrões contábeis de apuração de custos para itens de estoque, em que o custo é computado a partir do consumo, ou seja, a partir de sua saída do estoque. Com base no referido critério, foram selecionados os itens: feijão, arroz, açúcar, frango, batata e banana.

Com o propósito de abarcar as peculiaridades dos diferentes tipos de Organizações Militares da Marinha do Brasil, extraiu-se os históricos de consumo dos seis itens selecionados referentes ao Municciamento de seis tipos de OM, quais sejam: uma OM de Ensino, uma OM Administrativa, um Hospital Naval, um Navio, duas OM do Corpo de Fuzileiros Navais e uma Base da MB, totalizando sete OM e sete processos preditivos, tendo em vista que cada método (Holt-Winters e ARIMA) gerou dois tipos de previsões (mensal e acumulado).

Ao desenvolver o estudo em lide, foi possível verificar que a principal ferramenta de controle dos estoques de alimentos utilizada pelos gestores da MB é o sistema Quaestor. O referido sistema dispõe de funcionalidades que permitem a realização do controle físico e contábil dos gêneros alimentícios, bem como a emissão de relatórios que auxiliam o acompanhamento do fluxo de entrada e saída dos itens nos estoques das OM. Contudo, sob o

prisma do planejamento e controle dos estoques de alimentos, constatou-se a ausência da disponibilidade de ferramentas e mecanismos que proporcionem aos gestores a estrutura necessária à realização de previsões de demanda dos alimentos. As atividades desenvolvidas pelos gestores limitam-se à realização do controle baseado nas informações geradas pelo Quaestor e pela emissão das Notas de Empenho no SIAFI, quando das contratações dos itens.

Sendo assim, a primeira possível contribuição oriunda desta pesquisa refere-se ao mecanismo proposto na realização das análises dos processos preditivos neste estudo, em que foram empregados recursos estatísticos operacionalizados pelo *software* R, que pode ser obtido sem custos para a administração pública. O sistema Quaestor, apesar de atender uma parcela importante das atividades executadas pelos gestores da MB, não dispõe de funcionalidades estatísticas que viabilizem a previsão de demanda.

Desta forma, o mecanismo proposto por esta pesquisa sugere à Administração Naval apenas a disponibilização de treinamentos e cursos no Centro de Instrução e Adestramento Almirante Newton Braga (CIANB) para a qualificação dos gestores para a realização de previsões de demanda por meio do *software* R, o que poderá trazer resultados gerenciais benéficos ao Municíamento das OM da Força, sobretudo no que concerne aos aspectos de planejamento e controle dos estoques de alimentos.

Na fase preliminar da execução dos processos preditivos, o presente estudo identificou mecanismos gerenciais que podem ser essenciais ao planejamento e controle dos estoques de gêneros alimentícios das OM da MB. Nesta fase, foram realizadas análises gráficas que demonstraram o comportamento do consumo dos alimentos ao longo dos anos em cada OM analisada na pesquisa, o que possibilitou a identificação de tendências e sazonalidades nos consumos, informações estas que podem ser elementos importantes para os gestores nas tomadas de decisão de incremento ou redução dos níveis de estoque.

No desenvolvimento das análises das previsões, adotou-se quatro mecanismos para a obtenção das previsões de consumo anual, baseadas nas abordagens dos métodos de Holt-Winters e Box & Jenkins, executadas pelas funções *HoltWinters* e *auto.arima* do *software* R. Dentre os resultados encontrados, constatou-se que o método de previsão acumulado de 12 meses de Holt-Winters foi o que apresentou os melhores resultados na previsão dos gêneros secos, apresentando pequenos desvios entre os resultados previstos e os montantes de consumo observados no ano de 2019. Enquanto o somatório das previsões de consumo mensais oriundos da metodologia Box & Jenkins apresentou os melhores resultados para as séries que indicaram maiores irregularidades nas demandas, no caso, as séries de consumo de frango em um navio e banana em uma OM do CFN.

A análise do processo de previsão de consumo de frango, em Kg, em um Hospital Naval da MB possibilitou a obtenção de um achado de pesquisa que pode ser útil ao sistema de controle interno da Força. Quando da obtenção das previsões mensais de consumo de frango no Hospital Naval, verificou-se que os valores observados no primeiro semestre de 2019, ou seja, as quantidades efetivamente consumidas de frango na OM naquele período, estavam em níveis de consumo bem abaixo dos valores previstos.

Com isto, a pesquisa avaliou que o processo de previsão de demanda pode ser utilizado como um instrumento de controle interno pelos gestores da Força, haja vista a possibilidade de evidenciação de desvios acentuados nos níveis de consumo dos alimentos nas OM frente às previsões obtidas pelos métodos estatísticos. Além disso, o referido processo se alinha aos preceitos inerentes à Teoria dos Contratos, que traz vínculo com os aspectos de controle, requerendo o embasamento quantitativo robusto das quantidades dos materiais inseridas nos contratos.

Em paralelo, as previsões de demanda dos alimentos podem ser importantes componentes na elaboração do Programa de Aplicação de Recursos (PAR) ou plano de contratações anual, como é chamado na lei de licitações de contratos. No referido documento são elencadas as previsões das necessidades de materiais e serviços de todos os setores da OM, dentre eles o Municíamento. Após a elaboração deste documento, o nível estratégico das OM decide pelas prioridades de contratações frente à previsão de alocação de recursos orçamentários para o exercício subsequente, o que reforça a importância da precisão das informações contidas neste documento, de forma que não haja imobilização de capital desnecessariamente.

Adicionalmente, ressalta-se as recentes emissões de dispositivos legais por parte do governo federal que deram ênfase ao princípio do planejamento na Administração Pública. Em um primeiro momento, foi emitida a IN nº 40/2020 do Ministério da Economia, que trouxe um maior detalhamento acerca da elaboração dos Estudos Técnicos Preliminares (ETP) para os órgãos sob a esfera federal. Em seguida, em 01 de abril de 2021, foi publicada a Lei nº 14.133/2021, conhecida como a “nova lei de licitações contratos”. Em ambos os dispositivos legais o ETP fora abordado como um instrumento de planejamento obrigatório para os processos de contratações de bens pelos órgãos públicos.

Cabe destacar o contido no texto dos referidos documentos, que trouxe a necessidade de os órgãos realizarem previsões com base em métodos quantitativos, baseadas no histórico de consumo de cada item, de forma que as quantidades a serem inseridas nos processos licitatórios estejam amparadas por tais cálculos.

Nesse diapasão, a Marinha do Brasil como órgão público federal, deve atentar aos novos preceitos e exigências fixadas pela administração pública. Com isto, esta pesquisa avaliou que os mecanismos empregados neste estudo para a obtenção das previsões podem ser úteis ao processo de planejamento das aquisições de alimentos das OM da MB. Os resultados obtidos pelo método acumulado de 12 meses de Holt-Winters, apresentaram desvios relativos considerados baixos, além de se obter um intervalo de confiança que pode ser utilizado como estratégia frente às flutuações das demandas e possíveis incertezas advindas do cenário macroeconômico do País, que por sua vez, pode afetar o fornecimento dos itens em alguns casos.

A utilização do intervalo de confiança possibilita ao Municíamento das OM executar um planejamento mais robusto das contratações, haja vista que mitiga os riscos de realização de aditivos e novos processos licitatórios, além de preservar a economia de escala nas aquisições dos alimentos. Relewa mencionar que, os pregões eletrônicos realizados para as contratações dos alimentos originam as chamadas atas de registro de preços (ARP). De acordo com a Lei 14.133/2021, as quantidades inseridas nas ARP não geram a obrigatoriedade de contratação por parte dos órgãos da administração pública, embora, gere a obrigatoriedade de fornecimento por parte das empresas vencedoras do processo, quando demandadas pela administração pública.

Desta forma, caso as previsões estabeleçam quantidades maiores do que as efetivamente consumidas em um determinado exercício, não há o risco de prejuízos aos cofres públicos, uma vez que não há obrigatoriedade de contratação da totalidade das quantidades, além dos itens poderem ser solicitados ao longo no ano, conforme a gestão de cada OM e necessidade de ressurgimento dos estoques de alimentos.

Tendo em vista que as OM da MB executam atividades estratégicas de defesa no País, a adoção do limite superior do intervalo de confiança obtido nos processos de previsão utilizados nesta pesquisa, pode ser empregado como parâmetro na elaboração dos ETP, possibilitando às OM adquirirem quantidades suficientes para o estabelecimento de um estoque de segurança frente às possíveis incertezas de fornecimento. Além disso, os gestores podem se valer destas quantidades para o máximo abastecimento dos estoques sem a necessidade de efetuar contratações desamparadas por processos licitatórios, corroborando assim para melhores práticas contábeis frente aos órgãos de controle interno e externo do governo federal.

Adicionalmente, utilizou-se a combinação das previsões obtidas pelos métodos HW1 e BJ1, o que possibilitou observar a melhora na precisão de alguns resultados, apresentando-se

como mais uma opção de mecanismo aos gestores, além de contribuir para a mitigação dos riscos que envolvem o processo preditivo.

No escopo da contabilidade gerencial da Força, as previsões de consumo podem ser utilizadas como subsídios para as projeções de custos de alimentos das OM, sobretudo nas atividades contábeis executadas pelo Sistema de Custos da Marinha (SCM). As previsões de demanda dos principais gêneros alimentícios utilizados pela MB remetem à uma estimativa de consumo destes itens, o que se alinha aos novos critérios contábeis oriundos do processo de convergência da contabilidade pública aos padrões contábeis internacionais, que passou a demandar o registro de informações contábeis no Sistema de Informações de Custos do Governo Federal (SIC). As informações de custos lançadas no citado sistema baseiam-se no consumo dos itens, e não na movimentação monetária para as suas aquisições.

Com isto, as previsões de consumo podem subsidiar as projeções de custos de determinados tipos de alimentos, além de refletir nos aspectos orçamentários e necessidades de recursos para suportar tais necessidades. Adicionalmente, as referidas projeções podem ser utilizadas como instrumentos comparativos em processos de cortes de custos, indicando gerencialmente os itens com maiores custos e suas correspondentes essencialidades frente às necessidades do Municíamento de cada OM da MB.

Nesse prisma, o referido estudo avaliou que o processo de previsão de demanda, baseado em métodos estatísticos, pode trazer possíveis benefícios ao Municíamento da Força, sobretudo no que concerne aos prismas financeiro, orçamentário, patrimonial e de controle. As tarefas de planejamento e controle dos gestores das OM podem se tornar mais robustas com a utilização destes processos gerenciais, podendo contribuir para a boa governança e gestão das aquisições, a fim de evitar desperdício de recursos públicos e mitigar as hipóteses de falhas administrativas.

Como sugestão de pesquisas futuras, sugere-se a avaliação destes mecanismos nos processos de compras centralizadas de alimentos realizadas pelos Centros de Intendência da Marinha, quando do abastecimento dos estoques de alimentos dos navios da MB. Além disso, o emprego de outros tipos de métodos estatísticos de previsão pode se tornar oportuno à identificação de novos achados de pesquisa que venham contribuir para o aperfeiçoamento do Municíamento da MB, sobretudo nos aspectos de planejamento e controle.

REFERÊNCIAS

- ALENCAR, C. O.; FONSECA, A. C. P. D. da. Excelência na gestão pública: a contribuição do controle interno da Marinha do Brasil. *REGE-Revista de Gestão*, v. 23, n. 2, p. 172-184, 2016. Disponível em: < <https://www.revistas.usp.br/rege/article/view/121141>>. Acesso em: 18 ago. 2020.
- ALMEIDA, D. M. *Modelos híbridos de séries temporais aplicados ao sistema automotivo OnBoard Diagnostics*. Recife, 2018, 75 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Pernambuco, Recife, 2018. Disponível em: <<https://repositorio.ufpe.br/handle/123456789/32682>>. Acesso em: 20 out. 2021.
- ALVES, K. R. B. *O estudo técnico preliminar como ferramenta de gestão no planejamento das contratações de materiais operacionais do CBMDF*. 2021. 202 f. Dissertação (Curso de Altos Estudos para Oficiais) – Corpo de Bombeiros Militar do Distrito Federal, Brasília, 2021. Disponível em: <<https://biblioteca.cbm.df.gov.br/jspui/handle/123456789/221>>. Acesso em: 25 jul. 2021.
- 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. Disponível em: < <https://www.producaoonline.org.br/rpo/article/view/3539>>. Acesso em: 20 set. 2020.
- AMORIM, T. M.; SOUZA, T. S. e. Gestão de risco: reflexões ao processo de implementação na Marinha do Brasil. In: Encontro Brasileiro de Administração Pública, VI, Salvador, 2019. *Anais...*, Salvador, 2019. Disponível em: <<https://ebap.online/ebap/index.php/ebap/viebab/paper/viewFile/655/177>>. Acesso em: 31 ago. 2021.
- BALLOU, R. H. *Gerenciamento da cadeia de suprimentos/logística empresarial*. 5. ed. Porto Alegre: Bookman, 2006.
- BARROS, A. C.; MATTOS, D. M. de; OLIVEIRA, I. C. L. de; FERREIRA, P. G. C.; DUCA, V. E. L. de A. *A Análise de Séries Temporais em R: curso introdutório*. 1. ed. São Paulo: Atlas, 2020.
- BORGES, T. B.; MARIO, P. C.; CARNEIRO, R. A implementação do sistema de custos proposto pelo governo federal: uma análise sob a ótica institucional. *Revista de Administração Pública*, v. 47, n. 2, p. 469-491, 2013. Disponível em: <<https://bibliotecadigital.fgv.br/ojs/index.php/rap/article/view/8070>>. Acesso em: 20 out. 2021.
- BRANDALISE, F.; FELLA, L. J.; ZAMIN, L. M. O contador público no contexto da gestão pública. *Revista de Administração e Ciências Contábeis do IDEAU*, v. 4, n. 8, p. 1-17, 2009. Disponível em: < https://www.caxias.ideau.com.br/wp-content/files_mf/4e7e042a6738a3c142cf71a76e5ed0f1112_1.pdf>. Acesso em: 19 ago. 2021.

BRANDÃO, N. B.; OLIVEIRA, M. B. de; ALEXANDRE, J. W. C.; FREITAS, S. M. de. Aplicação de gráficos com limites móveis na modelagem da demanda de passageiros do aeroporto internacional de Belém a partir da suavização exponencial de Holt-Winters. In: Encontro Nacional de Engenharia de Produção, 32, Bento Gonçalves, 2012. *Anais...*, Bento Gonçalves, 2012. Disponível em: <<https://www.semanticscholar.org/paper/Aplica%C3%A7%C3%A3o-de-gr%C3%A1ficos-de-controle-com-limites-na-da-Brand%C3%A3oOliveira/82ba5e56a253fcbc1ca7b4cc447b74d4a281055d>>. Acesso em: 13 set. 2021.

BRASIL. Marinha do Brasil. Secretaria-Geral da Marinha. *Normas para a gestão do plano diretor – SGM-401*. Brasília, DF, 2014. - 1ª Edição - Rev. 1.

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.

BRASIL. Ministério da Defesa. Estado-Maior Conjunto das Forças Armadas. *Doutrina de Logística Militar – MD42-M-02*. Brasília, DF, 2016. – 3ª Edição.

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. Disponível em: <<https://www.in.gov.br/en/web/dou/-/lei-n-14.133-de-1-de-abril-de-2021-311876884>>. Acesso em: 12 mai. 2021.

BRASIL. Tribunal de Contas da União. *Acórdão nº 4.039/2020*. Plenário. Relator: Ministro Walton Alencar Rodrigues. Sessão de 8/12/2020. Disponível em: <<https://www.in.gov.br/en/web/dou/-/ata-n-47-de-8-de-dezembro-de-2020-294651594>>. Acesso em: 25 ago. 2021.

BRASIL. Tribunal de Contas da União. *Acórdão nº 1.425/2021*. 2ª Câmara. Relator: André de Carvalho. Sessão de 26/01/2021. Disponível em: <<https://pesquisa.apps.tcu.gov.br/#/pesquisa/acordao-completo>>. Acesso em: 25 ago. 2021.

CAETANO, R. D.; BORINELLI, M. L.; ROCHA, W. Processo de aquisições na gestão pública brasileira: aplicação da metodologia de cálculo do custo total de propriedade. In: CONGRESSO BRASILEIRO DE CUSTOS, XXVI, Curitiba, 2019. *Anais...*, Curitiba, 2020. Disponível em: <<https://anaiscbc.emnuvens.com.br/anais/article/viewFile/4642/4660>>. Acesso em: 29 out. 2020.

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*. 2006. Disponível em: <<https://anaiscbc.emnuvens.com.br/anais/article/view/1871>>. Acesso em: 31 março 2021.

- CARDOSO, C. A. V.; CRUZ, G. L. Forecasting natural gas consumption using ARIMA models and artificial neural networks. *IEEE Latin America Transactions*, v. 14, n. 5, p. 2233-2238, 2016. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/7530418>>. Acesso em: 01 abril 2021.
- CARDOSO, L. F.; MELLO, L. S. C. de; DUQUE, A. P. O.; ALVES, F. J. S. A Teoria Econômica da Regulação nas pesquisas científicas em contabilidade. In: Encontro da Associação Nacional de Pós-Graduação e Pesquisa em Administração, 45, on-line, 2021. *Anais...*, on-line, 2021. Disponível em: <http://anpad.com.br/pt_br/event/details/114>. Acesso em: 31 jan. 2022.
- CARVALHO, L. R. *Previsão de demanda de material de saúde na Marinha do Brasil*. 2018. 105 f. Dissertação (Mestrado em Logística) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2018. Disponível em: <<https://www.maxwell.vrac.puc-rio.br/36255/36255.PDF>>. Acesso em: 21 abril 2021.
- CASIMIRO, L. M. S. M. de; MORAES, F. Planejamento social na administração pública: um instrumento essencial na promoção dos direitos fundamentais sociais. *Revista de Direito Econômico e Socioambiental*, v. 8, n. 2, p. 443-461, 2017. Disponível em: <<https://periodicos.pucpr.br/index.php/direitoeconomico/article/view/20947>>. Acesso em: 25 ago. 2021.
- CHATFIELD, C.; YAR, M. Holt-Winters forecasting: some practical issues. *Journal of the Royal Statistical Society*, v. 37, n. 2, p. 129-140, 1988. Disponível em: <<https://www.jstor.org/stable/2348687>>. Acesso em: 02 set. 2021.
- CHING, H. Y. *Gestão de estoques na cadeia de logística integrada: supply chain*. 4. ed. São Paulo: Atlas, 2016.
- CONSTANTINI, M.; PAPPALARDO, C. A hierarchical procedure for the combination of forecasts. *International Journal of Forecasting*, v. 26, n. 4, p. 725-743, 2010. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0169207009001423>>. Acesso em: 07 fev. 2022.
- COSTA, A. F. da; BRAGA, C. R. A.; ANDRIOLI, L. G. G. Estudos técnicos preliminares: o calcanhar de Aquiles das aquisições públicas. *Revista do TCU*, v. 49, n. 139, p. 38-51, 2017. Disponível em: <<https://revista.tcu.gov.br/ojs/index.php/RTCU/issue/view/82>>. Acesso em: 25 ago. 2021.
- DIAS FILHO, J. M. Novos desenvolvimentos teóricos em contabilidade. *Revista de Contabilidade da UFBA*, v. 2, n. 2, p. 2-3, 2008. Disponível em: <<https://periodicos.ufba.br/index.php/rcontabilidade/article/view/20412/14866>>. Acesso em: 24 mar. 2020.
- ENAMI, L. M.; LEAL, G. C. L.; GIRANZOTTO, D. C. T. Modelos de séries temporais: uma aplicação à previsão de demanda de medicamentos. In: Simpósio de Engenharia, Gestão e Inovação, 3, São Paulo, 2020. *Anais...*, São Paulo, 2020. Disponível em: <<https://www.even3.com.br/anais/sengi2020/271128-modelos-de-series-temporais--uma-aplicacao-a-previsao-de-demanda-de-medicamentos/>>. Acesso em: 14 out. 2021.

FONSECA, L. C. de A.; SANTOS, R. F.; LIMA, T. F. Previsão de demanda intermitente: uma investigação empírica na cadeia de sobressalentes da Marinha do Brasil. *Acanto em Revista*, v. 6, n. 6, p. 16-33, 2019. Disponível em: <https://www.marinha.mil.br/cianb/acanto_em_revista>. Acesso em 21 abril 2021.

FREITAS, R.; CARPES, A. de M.; PIVETA, M. N.; CARVALHO, B. de M.; TRINDADE, R. T. A gestão de estoque nas organizações: uma análise crítica entre a iniciativa pública e privada. *DESENVOLVE: Revista de Gestão do Unilasalle*, v. 9, n. 1, p. 105-122, 2020. Disponível em: <<https://revistas.unilasalle.edu.br/index.php/desenvolve/article/view/5663>>. Acesso em: 02 out. 2020.

GARCIA, E. S.; DOS REIS, L. M. T. V.; MACHADO, L. R. FERREIRA FILHO, V. J. M. *Gestão de estoques: otimizando a logística e a cadeia de suprimentos*. 1. ed. Rio de Janeiro: E-Papers Serviços Editoriais, 2006.

GHIANI, G.; LAPORTE, G.; MUSMANNO, R. *Introduction to logistics systems planning and control*. Chichester, England: John Wiley & Sons, 2004.

GUERRA, J. H. L. Proposta de um protocolo para o estudo de caso em pesquisas qualitativas. In: Encontro Nacional de Engenharia de Produção, 30, São Carlos, 2012. *Anais...*, São Carlos, 2010. Disponível em: <http://www.abepro.org.br/biblioteca/enegep2010_TN_STO_133_848_14839.pdf>. Acesso em: 20 out. 2021.

GUJARATI, D. N.; PORTER, D. C. *Econometria básica*. 5. ed. Porto Alegre: Bookman, 2011.

GUIMARÃES, D. C.; FONSECA, L. S. da; RUSSO, S. L. Modelagem Holt-Winters da evolução dos depósitos de patentes no Brasil. In: Simpósio de Pesquisa Operacional & Logística da Marinha, 18, Rio de Janeiro, 2015. *Anais...*, Rio de Janeiro, 2015. Disponível em: <<https://www.proceedings.blucher.com.br/article-details/modelagem-holt-winters-da-evolucao-dos-depositos-de-patentes-no-brasil-22696>>. Acesso em: 27 set. 2021

HOOVER, J. The UFO Project: Initial Survey Results. *Foresight: The International Journal of Applied Forecasting*, n. 60, p. 45-47, 2021. Disponível em: <<https://forecasters.org/foresight/bookstore/>>. Acesso em: 03 jun. 2021.

HOFFMANN, D. de L. *Planejamento de compras em uma universidade pública da região norte*. 2011. 49 f. Dissertação (Curso Superior de Tecnologia em Logística) – Instituto Federal de Educação, Ciência e Tecnologia de Bento Gonçalves, Rio Grande do Sul, 2011. Disponível em: <<https://docplayer.com.br/1128254-Planejamento-de-compras-em-uma-universidade-publica-da-regiao-norte.html>>. Acesso em: 27 set. 2021.

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. Disponível em: <<http://cran.rediris.es/web/packages/forecast/vignettes/JSS2008.pdf>>. Acesso em 20 abril 2021.

IUDÍCIBUS, Sergio de; LOPES, Alexandro Broedel. *Teoria avançada da contabilidade*. 2. ed. São Paulo: Atlas, 2012.

IUDÍCIBUS, S. de; NIYAMA, J.K.; OLIVEIRA, V.R.S; BEUREN, I.M. Reflexões sobre as bases filosóficas dos princípios contábeis. *Revista Contemporânea de Contabilidade*, v. 17, n. 42, p. 158-173, 2020.

Disponível em: <<https://periodicos.ufsc.br/index.php/contabilidade/article/view/2175-8069.2020v17n42p158>>. Acesso em: 02 abr. 2021.

JACOB JÚNIOR, A. B.; OLIVEIRA, F. M. de; PÁDUA, F. L. D.; MATIAS, M. A.; DAYRELL, V. M. In: Encontro Nacional de Engenharia de Produção, 38, Alagoas, 2018. *Anais ...*, Alagoas, 2018. Disponível em:

<http://www.abepro.org.br/biblioteca/TN_STO_258_480_36540.pdf>. Acesso em: 14 out. 2021.

JUSTEN FILHO, M. *Comentários à lei de licitações e contratações administrativas*. São Paulo: Revista dos Tribunais, 2021.

LAZARIN, D. F.; STURARO, V. A.; SILVA, G. B. da; CASTILLO, L. A. M. Análise de métodos de previsão de demanda de séries temporais: estudo de caso em uma empresa fabricante de máquinas e equipamentos eletromecânicos. *Brazilian Journal of Development*, v. 5, n. 12, p. 28479-28492, 2019. Disponível em:

<<https://www.brazilianjournals.com/index.php/BRJD/article/view/5123>>. Acesso em: 20 out. 2021.

LIMA, J. E. C.; CASTRO, L. F. de; CARTAXO, G. A. A. 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*, v. 13, n. 46, p. 892-913, 2019. Disponível em: <<https://idonline.emnuvens.com.br/id/article/view/1875>>. Acesso em: 23 abril 2021.

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. Disponível em:

<<https://www.scielo.br/j/rap/a/sYYrhjhyGpwryFBcPP7xjz/?format=pdf&lang=pt>>. Acesso em: 08 nov. 2021.

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

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. Disponível em: <<https://doi.org/10.1371/journal.pone.0194889>>. Acesso em: 27 ago. 2021.

MALHOTRA, N. K. *Pesquisa de marketing: uma orientação aplicada*. 6. ed. Porto Alegre: Bookman, 2012.

MARTIN, A. C.; HENNING, E.; WALTER, O. M. F. C.; KONRATH, A. C. Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville. *Revista Espacios*, v. 37, n. 6, p. 29-42, 2016. Disponível em:

<<https://qualimetria.ufsc.br/files/2016/05/Revista-ESPACIOS--Vol.pdf>>. Acesso em: 14 out. 2021.

MARTINS, P. G.; ALT, P. R. C. *Administração de recursos materiais e recursos patrimoniais*. 3. ed. São Paulo: Saraiva, 2009.

MARTÍNEZ, F.; FRÍAS, M. P.; CHARTE, F.; RIVERA, A. J. Time series forecasting with knn in R: the tsfkn package. *The R Journal*, v. 11, n. 2, p. 229-242, 2019. Disponível em: <<https://journal.r-project.org/archive/2019/RJ-2019-004/RJ-2019-004.pdf>>. Acesso em: 18 ago. 2020.

MATIAS, A. B.; CAMPELLO, C. A. G. B. *Administração financeira municipal*. São Paulo: Atlas, 2000.

MELO, R. V. de; FRUJUELLE, R.; BRAGA, A. L. Uma Análise do Uso de Peças de Reposição na Manutenção de Frotas de Veículos em uma Empresa de Transporte Coletivo do Sul Fluminense. In: *SEGeT – Simpósio de Excelência em Gestão e Tecnologia*, XIII, Resende, 2016. *Anais ...*, Resende, 2016. Disponível em: <<https://www.aedb.br/seget/arquivos/artigos16/10024189.pdf>>. Acesso em: 12 jul. 2021.

MELO, R. V. de; SCRAMIN, A.; RESENDE FILHO, S. de; MELO, C. V. F. de. A eficiência na gestão dos estoques contribuindo para a lucratividade das empresas. In: Congresso de Administração, Sociedade e Inovação, 13, Rio de Janeiro, 2021. *Anais ...*, Rio de Janeiro, 2021. Disponível em: <<https://www.even3.com.br/anais/casi2020/329469-a-eficiencia-na-gestao-dos-estoques-contribuindo-para-a-lucratividade-das-empresas/>>. Acesso em: 20 out. 2021.

MELLO, M. P.; PETERNELLI, L. A. *Conhecendo o R: uma visão mais que estatística*. 1. ed. Viçosa: UFV, 2013.

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. Disponível em: <<https://www.even3.com.br/anais/casi2020/325853-A-UTILIZACAO-DE-METODOS-DE-PREVISAO-DE-DEMANDA-NAS-ATIVIDADES-CONTABEIS-DA-GESTAO-DE-ESTOQUES-DE-ALIMENTOS-DA-MAR>>. Acesso em: 05 jul. 2021.

MELLO, L. S. C. de; SANTOS JUNIOR, M. T. dos; PESSANHA, J. F. M. Um modelo de regressão linear múltipla para a gestão contábil de alimentos dos navios da Marinha do Brasil. In: Simpósio de Engenharia, Gestão e Inovação, 4, Juazeiro do Norte, 2021. *Anais...*, Juazeiro do Norte, 2021. Disponível em: <<https://www.even3.com.br/anais/sengi2021/349266-UM-MODELO-DE-REGRESSAO-LINEAR-MULTIPLA-PARA-A-GESTAO-CONTABIL-DE-ALIMENTOS-DOS-NAVIOS-DA-MARINHA-DO-BRASIL>>. Acesso em: 26 jul. 2021.

MELLO, L. S. C. de; PESSANHA, J. F. M. Previsão de demanda no planejamento das aquisições de alimentos em organizações militares da Marinha do Brasil. In: Congresso UFSC de Controladoria e Finanças, 11, On-line, 2021. *Anais...*, On-line, 2021. Disponível em: <<https://daankrug.github.io/ccn-ufsc-cdn/11CCF/index.html?>>. Acesso em: 07 fev. 2022.

MENDES, R. G. *O processo de contratação pública – fases, etapas e atos*. Curitiba: Editora Zênite, 2012.

MIGUEL, P. A. C. Estudo de caso na engenharia de produção: estruturação e recomendações para a sua condução. *Produção*, v. 17, n. 1, p. 216-229, 2007. Disponível em: <<https://www.scielo.br/j/prod/a/zhVnv4mW8pvWc3hTxvfXt4L/?lang=pt>>. Acesso em: 19 ago. 2021.

MINISTÉRIO DA ECONOMIA (ME). Secretaria Especial de Desburocratização, Gestão e Governo Digital. Instrução Normativa n. 40, de 22 de maio de 2020. Diário Oficial da República Federativa do Brasil, Brasília, DF, 26 mai. 2020. Seção I. Disponível em: <<https://www.in.gov.br/en/web/dou/-/instrucao-normativa-n-40-de-22-de-maio-de-2020-258465807>>. Acesso em: 19 nov. 2020.

MIRANDA, R. F. Q. Impactos da utilização de sistema de informação logístico no compartilhamento de informações na cadeia de suprimento de sobressalentes da Marinha do Brasil. *Acanto em Revista*, v. 1, n. 1, p. 106-116, 2014. Disponível em: <https://www.marinha.mil.br/cianb/acanto_em_revista>. Acesso em: 27 ago. 2021.

MOREIRA, D. A. *Administração da produção e operações*. 2. ed. São Paulo: Cengage Learning, 2012.

MORETTIN, P. A.; TOLOI, C. M. C. *Análises de Séries Temporais*. 3. ed. São Paulo: Blucher, 2018.

NOWOTARSKI, J.; WERON, R. To combine or not combine? Recent trends in electricity price forecasting. *HSC Research Report*, v. 16, n. 1, p. 1-6, 2016. Disponível em: <<https://ideas.repec.org/p/wuu/wpaper/hsc1601.html>>. Acesso em: 07 fev. 2022.

OLIVEIRA JUNIOR, J. N. de. Orçamento por resultados: aprimoramentos ao processo orçamentário da Marinha do Brasil. *Acanto em Revista*, v. 7, n. 7, p. 120-134, 2020. Disponível em: <<https://pt.calameo.com/read/0057038179bc34af3cde3>>. Acesso em: 20 out. 2021.

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, p. 43-64, 2001. Disponível em: <<https://www.scielo.br/pdf/prod/v11n1/v11n1a04.pdf>>. Acesso em: 21 nov. 2020.

PEREIRA, A. G.; BRUNI, A. L.; ROCHA, J. S. da; LIMA FILHO, R. N.; FARIA, J. A. de. Teoria dos Contratos, governança corporativa e auditoria: delineamentos para a discussão em teoria da contabilidade. In: Simpósio de Excelência em Gestão e Tecnologia, 7, Resende, 2010. *Anais...*, Resende, 2010. Disponível em: <<https://www.aedb.br/seget/artigos2010.php?pag=93>>. Acesso em: 31 jan. 2022.

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. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0169207018300232>>. Acesso em: 27 ago. 2020.

POCHIRAJU, B.; SESHADRI, S. *Essentials of business analytics*. International Series in Operations Research & Management Science, 264. Springer Nature Switzerland, 2019.

POZO, H. *Administração de recursos materiais e patrimoniais: uma abordagem logística*. 6. ed. São Paulo: Atlas, 2010.

R DEVELOPMENT CORE TEAM .R: a language and environment for statistical computing. *R Foundation for Statistical Computing*, Vienna, Austria, 2021. Disponível em: <<http://www.R-project.org>>. Acesso em: 27 abril 2021.

REIS, A. C. B.; SILVA, C. M. A. da; ALVES, S. M.; SOUSA, N. S. S. de; CANTUÁRIO, J. N. Análise da previsão de demanda e gestão de estoque no setor hortifruti em um mercado de bairro. *Brazilian Journal of Development*, v. 5, n. 12, p. 31840-31853, 2019. Disponível em: <<https://www.brazilianjournals.com/index.php/BRJD/issue/view/73>>. Acesso em: 10 ago. 2021.

SAAVEDRA-NIEVES, A. Inventorymodel: an R Package for Centralized Inventory Problems. *The R Journal*, v. 10, p. 200-217, 2018. Disponível em: <<https://journal.r-project.org/archive/2018/RJ-2018-023/index.html>>. Acesso em: 13 ago. 2020.
SAGAERT, Y. R.; KOURENTZES, N.; AGHEZZAF, E.; DESMET, B. Tactical sales forecasting using a very large set of macroeconomic indicators. *European Journal of Operational Research*, v. 264, n. 2, p. 558-569, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0377221717305957>>. Acesso em: 14 out. 2021.

SANTANA, E. C. de; 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. Disponível em: <<http://www.atenas.org.br/revista/ojs2.2.306/index.php/pensarcontabil/article/view/2303>>. Acesso em: 27 ago. 2021.

SANTOS, T. S. dos; ALVES, L. F. Aplicação de métodos de previsão de demanda e gestão de estoque em um produto de um supermercado na cidade de Marabá-PA. In: Encontro Nacional de Engenharia de Produção, 37, Joinville, 2017. *Anais ...*, Joinville, 2017. Disponível em: <http://www.abepro.org.br/biblioteca/TN_STP_238_378_31086.pdf>. Acesso em: 14 out. 2021.

SANTOS, A. S. L.; OLIVEIRA, S. C. de. Análise do controle de estoque: um estudo realizado na escola Raimundo Saraiva Coelho no município de Juazeiro do Norte/CE. In: Congresso de Administração, Sociedade e Inovação, XIII, Juiz de Fora, 2016. *Anais ...*, Juiz de Fora, 2016. Disponível em: <<https://www.even3.com.br/anais/casi/37067-analise-do-controle-de-estoque--um-estudo-realizado-na-escola-raimundo-saraiva-coelho-no-municipio-de-juazeiro-do-/>>. Acesso em: 11 ago. 2021.

SANTOS, M.; PIMENTA, V. A.; CARVALHO, F. B.; LAURIA, R. L.; SOUZA, J. A. Uma estratégia de otimização em navios de guerra da Marinha do Brasil. *Brazilian Journal of Development*, v. 4, n. 6, p. 3015-3034, 2018. Disponível em: <<https://www.brazilianjournals.com/index.php/BRJD/article/view/308>>. Acesso em: 08 nov. 2021.

SCHEFFER, D.; SOUZA, A. M.; ZANINI, R. R. Utilização de modelos ARIMA para previsão da arrecadação de ICMS do Estado do Rio Grande do Sul. XVII Simpósio de Pesquisa Operacional e Logística da Marinha-SPOLM. *Anais...* São Paulo, 2014. Disponível em: <<http://pdf.blucher.com.br/s3-sa-east.1.amazonaws.com/marineengineeringproceedings/spolm2014/127111.pdf>>. Acesso em: 31 março 2021.

SCRIVANO, N. F. T.; COSTA, P. C. F. da; 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. Disponível em: <<https://portaldeperiodicos.marinha.mil.br/index.php/acantoemrevista>>. Acesso em: 03 nov. 2020.

SILVA, E. L. da; MENEZES, E. M. *Metodologia da pesquisa e elaboração de dissertação*. 3. ed. Florianópolis: Laboratório de Ensino a Distância da Universidade Federal de Santa Catarina, 2001.

SILVA, M. G.; RABELO, M. H. S. Importância do Controle de Estoques Para as Empresas. *Revista Acadêmica Conecta FASF*, v2, n. 1, p. 238-254, 2017. Disponível em: <<http://revista.fasf.edu.br/index.php/conecta/article/view/63/pdf>>. Acesso em: 12 jul. 2021.

SILVA, N. da S.; OLIVEIRA, M. L. S.; ALMEIDA, J. S. C.; COUTO, C. de S. Planejamento público orçamentário e a teoria institucional: uma análise na região do território do Piemonte Norte do Itapicuru – BA. In: Encontro da Associação Nacional de Pós-Graduação e Pesquisa em Administração, 42, 2018, Curitiba. *Anais ...*, Curitiba, 2018. Disponível em: <<https://login.semead.com.br/20semead/arquivos/533.pdf>>. Acesso em: 08 nov. 2021.

SILVA, D. A.; SANTOS, M. E.; COSTA, D. F. A utilização do modelo Holt-Winters na elaboração de um orçamento de resultado de uma cooperativa de crédito rural. *Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ*, v. 21, n. 1, p. 39-56, 2016. Disponível em: <<http://www.spell.org.br/documentos/ver/41278/a-utilizacao-do-modelo-holt-winters-na-elaboracao-de-um-orcamento-de-resultado-de-uma-cooperativa-de-credito-rural>>. Acesso em: 10 set. 2020.

SILVA, R. L. da. *Compras centralizadas e descentralizadas: estudo de caso sobre os impactos de um modelo híbrido de compras na obtenção de gêneros alimentícios pela Marinha do Brasil*. 2016. 124 f. Dissertação (Mestrado em Logística) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2016. Disponível em: <<https://www.maxwell.vrac.puc-rio.br/28236/28236.PDF>>. Acesso em: 21 abril 2021.

SILVA, S. A. L.; SANT'ANA, N. L. S.; MENEZES, J. P. C. B.; PAULA, J. S.; CHAIN, C. P. Métodos e técnicas quantitativas em contabilidade e finanças: uma análise sob a ótica do software R. *Revista Pensar Contábil*, v. 19, n. 68, p. 37-46, 2017. Disponível em: <<http://www.atena.org.br/revista/ojs-2.2.3-06/index.php/pensarcontabil/article/view/3053>>. Acesso em: 15 ago. 2020.

SILVA, D. A.; SANTOS, M. E.; COSTA, D. F. A utilização do modelo Holt-Winters na elaboração de um orçamento de resultado de uma cooperativa de crédito rural. *Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ*, v. 21, n. 1, p. 39-56, 2016. Disponível em: <<http://www.spell.org.br/documentos/ver/41278/a-utilizacao-do-modelo-holt-winters-na-elaboracao-de-um-orcamento-de-resultado-de-uma-cooperativa-de-credito-rural>>. Acesso em: 10 set. 2020.

SILVA, M. C. da; SILVA, J. D. G. da; BORGES, E. F. Análises de componentes principais para elaborar índices de desempenho no setor público. *Revista Brasileira de Biometria*, v. 33, n. 3, p. 291-309, 2015. Disponível em: <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2828289>. Acesso em: 02 abr. 2021.

SOBRAL, P. V. N. C.; NETO, R. da S. O pregão eletrônico como ferramenta de eficiência na gestão pública. *International Journal of Professional Business Review*, v. 5, n. 1, p. 60-71, 2020. Disponível em: <<http://www.spell.org.br/documentos/ver/59230/o-pregao-eletronico-como-ferramenta-de-eficiencia-na-gestao-publica-->>. Acesso em: 31 ago. 2021.

SOEIRO, T. M.; WANDERLEY, C. A. A teoria institucional na pesquisa em contabilidade: uma revisão. *Revista Organizações & Sociedade*, v. 26, n. 89, p. 291-316, 2019. Disponível em: <<https://doi.org/10.1590/1984-9260895>>. Acesso em: 02 abr. 2021

SOUSA, C. B. de; BATISTA, D. G.; ANDRADE, N. de A. O planejamento como base da contabilidade para a gestão pública. *Pensar Contábil*, v. 6, n. 24, p.45-50, 2004. Disponível em: <<http://www.atena.org.br/revista/ojs-2.2.3-06/index.php/pensarcontabil/article/view/2321>>. Acesso em: 19 ago. 2021.

SOUSA, D. C. F.; CLAUDINO, C. N. de Q.; AQUINO, J. T. de; MELO, F. J. C. de. 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. Disponível em: <<http://www.spell.org.br/documentos/ver/51204/utilizacao-de-ferramentas-gerenciais-para-o-controle-de-estoques--um-estudo-de-caso-de-uma-empresa-do-setor-alimenticio>>. Acesso em: 13 ago. 2020.

SOUZA, J. A. F. de. *Previsão do número de veículos em fim de vida no Brasil: uma estimativa utilizando um modelo híbrido baseado no sarima e em redes neurais recorrentes*. 2020. 126 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Pernambuco, Caruaru, 2020. Disponível em: <<https://attena.ufpe.br/handle/123456789/38304>>. Acesso em: 23 abril 2021.

SOUZA, R. C.; CAMARGO, M. E. *Análise e previsão de séries temporais: os modelos ARIMA*. Ijuí: SEDIGRAF, 1996.

SPERANZA, T. F.; FERREIRA, P. G. C.; COSTA, J. A. da. SARIMA analysis and automated model reports with BETS, an R package. *The R Journal*, v. 10, n. 2, p. 133-147, 2018. Disponível em: <<https://pdfs.semanticscholar.org/b27b/49c7f3e94672e51a7946ab83e55905b80f8f.pdf>>. Acesso em: 20 abril 2021.

TAMBOSI, L. R.; DIAS, M. A. H. Desperdício de alimentos: agendas globais e articulação com movimentos locais. *REUNIR: Revista de Administração, Ciências Contábeis e Sustentabilidade*, v. 10, n. 2, p. 1-11, 2020. Disponível em: <<https://reunir.revistas.ufcg.edu.br/index.php/uacc/article/view/767>>. Acesso em: 19 set. 2020.

TONACIO JÚNIOR, P. C.; VERGARA, F. M. Os impactos da pandemia da COVID-19 nas aquisições públicas de material de saúde: uma análise sob a ótica do Sistema de Abastecimento da Marinha, v. 8, n. 8, p. 156-169, 2021. Disponível em: <<http://portaldeperiodicos.marinha.mil.br/index.php/acantoemrevista>>. Acesso em: 08 nov. 2021.

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. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0360544216305357>>. Acesso em: 27 jul. 2020.

VEIGA, C. P.; VEIGA, C. R. P. da; CATAPAN, A.; TORTATO, U.; SILVA, W. V. da. Demand forecasting in food retail: A comparison between the Holt-Winters and ARIMA models. *WSEAS transactions on business and economics*, v. 11, n. 1, p. 608-614, 2014. Disponível em: <<http://www.wseas.us/journal/pdf/economics/2014/a085707-276.pdf>>. Acesso em: 01 abril 2021.

WEISS, C. E.; RAVIV, E.; ROETZER, G. Forecast combinations in R using the Forecastcomb package. *The R Journal*, v. 10, n. 2, p. 262-281, 2018. Disponível em: <<https://journal.r-project.org/archive/2018/RJ-2018-052/index.html>>. Acesso em: 07 fev. 2022.

WERNER, L. Previsão da quantidade de leite cru industrializado no Rio Grande do Sul: usar modelos ou combinar modelos de previsão? In: Congresso Brasileiro de Engenharia de Produção, 9, Ponta Grossa, 2019. *Anais...*, Ponta Grossa, 2019. Disponível em: <http://aprepro.org.br/conbrepro/2019/anais/arquivos/09282019_170900_5d8fbbfc7a7bc.pdf>. Acesso em: 14 out. 2021.

ZANELLA, C.; VIEIRA, V.; BARICHELLO, R. Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. *GEPROS. Gestão da Produção, Operações e Sistemas*, v. 11, n. 1, p. 45-57, 2016. Disponível em: <<https://revista.feb.unesp.br/index.php/gepros/article/view/1310>>. Acesso em: 14 out. 2021.

APÊNDICE A – Séries temporais de consumo de alimentos

Tabela 58 – Série temporal de consumo de arroz em Kg

Mês	2014	2015	2016	2017	2018	2019
janeiro	2050	1470	1595	1616	1587	1380
fevereiro	847	1960	2050	1780	1710	1570
março	1370	2555	2755	2460	2190	1650
abril	3066	2155	2430	1720	2625	1620
maio	2502	2470	3203	2510	1735	1962
junho	1826	2215	2488	2098	2130	1648
julho	2300	2330	2027	1970	2035	1809
agosto	2503	2230	2287	2675	2255	2070
setembro	2602	2525	2690	2316	1860	1981
outubro	2781	2555	2320	2290	2090	1941
novembro	2258	2400	2245	2058	1935	1663
dezembro	1685	1395	1565	1231	845	905

Fonte: O autor, 2021

Tabela 59 – Série temporal de consumo de feijão em Kg

Mês	2014	2015	2016	2017	2018	2019
janeiro	174	187	232	275	246	254
fevereiro	205	161	208	212	215	229
março	198	214	184	250	238	249
abril	185	187	247	201	219	227
maio	222	167	245	264	258	262
junho	152	169	237	229	239	245
julho	215	248	228	221	232	232
agosto	201	184	249	233	247	229
setembro	235	186	231	260	267	264
outubro	212	184	213	208	224	226
novembro	259	138	223	202	211	222
dezembro	125	93	113	102	116	112

Fonte: O autor, 2021.

Tabela 60 – Série temporal de consumo de frango em Kg - HN

Mês	2014	2015	2016	2017	2018	2019
janeiro	7685	6474	5210	7344	7472	9988
fevereiro	6505	5514	5010	6487	5207	4316
março	6490	7051	2458	5854	5893	5312
abril	5574	4922	7608	6621	6159	6215
maio	7052	7481	8665	7545	7806	7587
junho	5941	7208	6340	7034	7497	7492
julho	6691	7831	6970	7426	9919	10300
agosto	6693	7469	7681	8728	9264	10563
setembro	8719	6050	7211	8459	10219	10202
outubro	5852	7223	7643	7911	8216	12079
novembro	5669	5468	6230	8855	9489	9012
dezembro	3958	3852	6841	5777	8048	7063

Fonte: O autor, 2021.

Tabela 61 – Série de consumo de frango em Kg - navio

Mês	2015	2016	2017	2018	2019
janeiro	38	35	86	31	45
fevereiro	28	34	40	42	62
março	55	68	53	52	114
abril	67	62	79	85	107
maio	30	42	58	73	49
junho	20	63	39	73	75
julho	36	45	83	115	31
agosto	44	66	94	136	56
setembro	38	77	41	40	50
outubro	25	44	56	105	145
novembro	21	72	35	43	64
dezembro	52	56	74	76	87

Fonte: O autor, 2021.

Tabela 62 – Série temporal de consumo de banana em Kg

Mês	2014	2015	2016	2017	2018	2019
janeiro	528	328	225	365	320	152
fevereiro	696	310	141	115	346	217
março	688	226	191	255	517	370
abril	552	467	195	351	448	841
maio	452	437	143	257	633	608
junho	955	554	145	295	642	342
julho	667	626	118	235	348	369
agosto	535	505	195	132	509	464
setembro	468	180	111	201	601	491
outubro	512	270	200	332	425	425
novembro	383	455	338	420	541	632
dezembro	609	142	68	385	355	440

Fonte: O autor, 2021.

Tabela 63 – Série temporal de consumo de açúcar em Kg

Mês	2014	2015	2016	2017	2018	2019
janeiro	745	705	638	696	640	590
fevereiro	929	654	787	587	684	581
março	903	820	726	697	690	598
abril	849	589	611	621	683	717
maio	908	875	561	535	617	610
junho	702	785	582	513	576	618
julho	1225	760	597	594	597	577
agosto	965	755	515	611	529	633
setembro	841	860	686	678	655	649
outubro	954	730	670	675	610	574
novembro	742	713	637	664	635	614
dezembro	536	532	565	516	500	503

Fonte: O autor, 2021.

Tabela 64 – Série temporal de consumo de batata em Kg

Mês	2014	2015	2016	2017	2018	2019
janeiro	587	309	570	355	442	381
fevereiro	498	270	282	293	145	213
março	607	294	280	414	318	335
abril	565	345	342	388	327	337
maio	489	353	445	601	339	367
junho	367	309	376	453	218	362
julho	404	361	136	466	83	178
agosto	541	271	206	395	531	412
setembro	298	350	231	348	380	242
outubro	523	263	321	521	401	406
novembro	300	202	151	301	308	248
dezembro	396	311	141	253	373	210

Fonte: O autor, 2021.

APÊNDICE B – Programa computacional empregado

Figura 95 – Códigos para obtenção das previsões mensais e acumulada - HW

```

Código em R para previsão de série temporal - Holt-Winters
library(forecast) # leitura do pacote para previsão
arquivo="C:/Users/Luiz Sérgio/Desktop/nomearq.csv" # carregamento dos dados
x=read.csv2(arquivo,header=T)
serie=ts(x[,3],freq=12,start=c(2014,1)) # transformando os dados em série temporal
# gráfico da série temporal
plot(serie,xlab="tempo",ylab="consumo de item",main="demanda de item")
summary(serie) # obtenção de dados da série
# decomposição da série em componentes não observáveis
plot(decompose(serie))
# ajuste do modelo e obtenção dos parâmetros de suavização
ajuste_com_sazonalidade=HoltWinters(serie)
ajuste_com_sazonalidade
# modelo multiplicativo
ajuste_com_sazonalidade_mult=HoltWinters(serie,seasonal="multiplicative")
ajuste_com_sazonalidade_mult
# ajuste sazonal
plot(serie,xlab="tempo",ylab="consumo de item",main="demanda de item")
lines(fitted(ajuste_com_sazonalidade)[,1],lwd=2,col="red")
legend(2014,xxx,c("consumo de item","Ajuste
HW"),lwd=c(1,2),col=c("black","red"),bty="n")
# obtenção das previsões
prev_hw=forecast(ajuste_com_sazonalidade,h=12,level=95)
prev_hw
# gráfico das previsões
plot(prev_hw,xlab="tempo",ylab="consumo de item em kg",main="demanda de item")

# Código para obtenção de previsão acumulada para o ano - Holt-winters
# Dados para o Estudo Técnico Preliminar
library(car)
library(forecast) # leitura do pacote para previsão
arquivo="C:/Users/Luiz Sérgio/Desktop/nomearq.csv" # carregamento dos dados
x=read.csv2(arquivo,header=T)
serie=x[,3]
anoinic_insamle=2014 # ano inicial
mesinic_insamle=1 # mes inicial
anofim_insamle=2018 # ano final
mesfim_insamle=12 # mes final
anoinic_outsamle=2019
mesinic_outsamle=1
anofim_outsamle=2019
mesfim_outsamle=12
serie_insamle=ts(serie,start=c(anoinic_insamle,mesinic_insamle),end=c(anofim_insamle,mesfim_insamle),freq=12)
serie_outsamle=window(serie,start=c(anoinic_outsamle,mesinic_outsamle),end=c(anofim_outsamle,mesfim_outsamle))
serie12=filter(serie_insamle,rep(1,12),sides=1)
serie12
# previsão HW
modelo=HoltWinters(window(serie12,start=c(2014,12),end=c(2018,12)))
forecast(modelo,h=12)

```

Fonte: O autor, 2021

Figura 96 – Código para obtenção da previsão mensal - BJ

```

# Código em R para previsão de série temporal - Box & Jenkins
# Leitura dos pacotes
library(forecast)
library(car)
library(portes)
# carregando os dados da série temporal
arquivo="C:/Users/Luiz Sérgio/Desktop/nomearq.csv"
x=read.csv2(arquivo,header=T)
# transformando os dados em série temporal
serie=ts(x[,3],freq=12,start=c(2014,1))
plot(serie,xlab="tempo",ylab="consumo de item kg",main="demanda de item")
# gráficos da fac e facp
acf(serie,lag=24)
pacf(serie,lag=24)

# função para fazer graficos
graficos<-function(modelo,separado){
  # modelo = modelo ajustado
  # separado = 1 , uma janela para cada grafico
  # separado = 0 , todos os gráficos juntos
  if (separado==0){
    par(mfrow=c(2,2))
    hist(modelo$residuals,xlab="residuos",ylab="frequencia",main="")
    titulo=paste("p-value",format(shapiro.test(modelo$residuals)$p.value,format="e"))
    qqPlot(modelo$residuals,main=titulo,ylab="quantis empiricos",xlab="quantis teóricos")
    acf(modelo$residuals,main="",ylab="FAC")
    pacf(modelo$residuals,main="",ylab="FACP")
  }else{
    windows()
    hist(modelo$residuals,xlab="residuos",ylab="frequencia",main="")
    windows()
    titulo=paste("Shapiro-Wilk's p-value",format(shapiro.test(modelo$residuals)$p.value,format="e"))
    qqPlot(modelo$residuals,main=titulo,ylab="quantis empiricos",xlab="quantis teóricos")
    windows()
    acf(modelo$residuals,main="",ylab="FAC")
    windows()
    pacf(modelo$residuals,main="",ylab="FACP")
  }
}

# função para calcular pvalor
pvalor<-function(modelo){
  coeficiente=coef(modelo)
  ep=sqrt(diag(modelo$var.coef))
  t=abs(coeficiente/ep)
  grau=length(serie)-sum(modelo$arma[c(1,2, 3, 4, 6, 7)])
  pvalor=2*pt(t,grau,lower.tail=F)
  return(pvalor)
}

# rodando o auto.arima
modelo=auto.arima(serie)
summary(modelo)

# variável dummy
dummy=rep(0,length(serie))
dummy2=rep(0,length(serie))
dummy[24]=1
dummy[48]=1
xreg=cbind(dummy1,dummy2)
modelo=auto.arima(serie,xreg=dummy)

# obtendo os gráficos do modelo
graficos(modelo,0)
# p-valor dos coeficientes
pvalor(modelo)
# p-valores da FAC
portest(modelo$residuals,lags=seq(1,24,1),test="LjungBox",MonteCarlo=TRUE)
# calculando as previsões
forecast(modelo,h=12)
# gráfico das previsões
plot(forecast(modelo,h=12),xlab="tempo",ylab="consumo de item em kg",main="demanda de item")

```

Fonte: O autor, 2021

Figura 97 – Código para obtenção da previsão acumulada – BJ

```

# previsão acumulada - Box & Jenkins
library(forecast)
library(car)
library(portes)
arquivo="C:/Users/Luiz Sérgio/Desktop/nomearq.csv"
x=read.csv2(arquivo,header=T)
serie=x[,3]
# gerando a estrutura do acumulado
anoinic_insample=2014 # ano inicial
mesinic_insample=1 # mes inicial
anofim_insample=2018 # ano final
mesfim_insample=12 # mes final
anoinic_outsample=2019
mesinic_outsample=1
anofim_outsample=2019
mesfim_outsample=12
serie_12=ts(serie, start=c(anoinic_insample,mesinic_insample), end=c(anofim_insample,mesfim_insample), freq=12)
serie_outsample=window(serie, start=c(anoinic_outsample,mesinic_outsample), end=c(anofim_outsample,mesfim_outsample))
serie12=filter(serie_12, rep(1,12), sides=1)
serie12
# função para fazer gráficos
graficos<-function(modelo, separado){
  # modelo = modelo ajustado
  # separado = 1 , uma janela para cada grafico
  # separado = 0 , todos os gráficos juntos
  if (separado==0){
    par(mfrow=c(2,2))
    hist(modelo$residuals, xlab="resíduos", ylab="frequencia", main="")
    titulo=paste("p-value", format(shapiro.test(modelo$residuals)$p.value, format="e"))
    qqPlot(modelo$residuals, main=titulo, ylab="quantis empiricos", xlab="quantis teóricos")
    acf(modelo$residuals, main="", ylab="FAC")
    pacf(modelo$residuals, main="", ylab="FACP")
  }else{
    windows()
    hist(modelo$residuals, xlab="resíduos", ylab="frequencia", main="")
    windows()
    titulo=paste("Shapiro-Wilk's p-value", format(shapiro.test(modelo$residuals)$p.value, format="e"))
    qqPlot(modelo$residuals, main=titulo, ylab="quantis empiricos", xlab="quantis teóricos")
    windows()
    acf(modelo$residuals, main="", ylab="FAC")
    windows()
    pacf(modelo$residuals, main="", ylab="FACP")
  }
}
# rodando o auto.arima
modelo=auto.arima(serie12)
summary(modelo)
# gerando os gráficos dos resíduos
graficos(modelo,1)
# Teste Ljung-Box
portest(modelo$residuals, lags=seq(1,24,1), test="LjungBox", MonteCarlo=TRUE)
# obtendo as previsões
forecast(modelo, h=12)
# variável dummy
dummy=rep(0, length(serie))
dummy2=rep(0, length(serie))
dummy[24]=1
dummy[48]=1
xreg=cbind(dummy1, dummy2)
modelo=auto.arima(serie, xreg=dummy)
# obtendo os gráficos do modelo
graficos(modelo,0)
# p-valor dos coeficientes
pvalor(modelo)
# p-valores da FAC
portest(modelo$residuals, lags=seq(1,24,1), test="LjungBox", MonteCarlo=TRUE)
# calculando as previsões
forecast(modelo, h=12)
# gráfico das previsões
plot(forecast(modelo, h=12), xlab="tempo", ylab="consumo de item em kg", main="demanda de item")

```

Fonte: O autor, 2021

Figura 98 – Códigos para obtenção das previsões combinadas

```

library(ForecastComb)
library(forecast)
# ENTRE COM OS NOMES DOS ARQUIVOS AQUI
historico=read.csv2("C:/Users/Luiz Sérgio/Desktop/batata20142018.csv", header=T) # arquivo com dados de 2014 até 2018
ano2019=read.csv2("C:/Users/Luiz Sérgio/Desktop/batata2019.csv", header=T) # arquivo com dados de 2019
# A PARTIR DESTA PONTO NAO PRECISA MODIFICAR O PROGRAMA
train=ts(historico[,3], start=c(2014,1), frequency=12) # serie usada no ajuste do modelode
teste=ts(ano2019[,2], start=c(2019,1), frequency=12) # serie usada no teste
h <- length(teste) # horizonte 12 meses
# PRIMEIRO MÉTODO DE COMBINAÇÃO DAS PREVISÕES (REGRESSÃO)
# AJUSTA MODELOS DE PREVISAO
ARIMA <- forecast(auto.arima(train, lambda=0), h=h) # previsao 12 passos a frente
HW <- forecast(HoltWinters(train), h=h) # previsao 12 passos a frente
# PREVISOES
prevARIMA=ARIMAFitted[-seq(1,12,1)] # previsao metodo ARIMA
prevHW=HWFitted[-seq(1,12,1)] # previsao metodo HW
X <- cbind(ARIMA=prevARIMA, HW=prevHW)
# PREVISOES 2019
prev2019HW=ts(ano2019[,3], start=c(2019,1), frequency=12) # previsao HW 2019
prev2019ARIMA=ts(ano2019[,4], start=c(2019,1), frequency=12) # previsao ARIMA 2019
# COMBINA PREVISOES
y=train[-seq(1,12,1)] # serie historica observada
MLpol0 <- mixture(model="MLpol", loss.type="square")
weights <- predict(MLpol0, X, type="weights")
combinada = tail(weights[,1,1])*prev2019ARIMA + tail(weights[,2,1])*prev2019HW
MAPEcombinado=round(100*mean(abs(combinada-teste)/teste),2)
MAPEHW=round(100*mean(abs(prev2019HW-teste)/teste),2)
MAPEARIMA=round(100*mean(abs(prev2019ARIMA-teste)/teste),2)
print(weights) # pesos
print(paste("MAPE HW =", MAPEHW, "%", " | MAPE ARIMA =", MAPEARIMA, "%", " | MAPE PREVISAO COMBINADA =", MAPEcombinado, "%"))
# previsao combinada para 2019
prev2019HW=ano2019[,3] # previsao HW para 2019 , dado de entrada
prev2019ARIMA=ano2019[,4] # previsao ARIMA para 2019 , dado de entrada
combinada = OLS_static$Intercept + OLS_static$weights[1]*prev2019ARIMA + OLS_static$weights[2]*prev2019HW
print(paste("Intercepto =", round(OLS_static$Intercept,4), " | PESO ARIMA =", round(OLS_static$weights[1],4), " | PESO HW =", round(OLS_static$weights[2],4)))
# MAPE %
MAPEcombinado=round(100*mean(abs(combinada-teste)/teste),2) # MAPE PREVISAO COMBINADA
MAPEHW=round(100*mean(abs(prev2019HW-teste)/teste),2) # MAPE HW
MAPEARIMA=round(100*mean(abs(prev2019ARIMA-teste)/teste),2) # MAPE ARIMA
print(paste("MAPE HW =", MAPEHW, "%", " | MAPE ARIMA =", MAPEARIMA, "%", " | MAPE PREVISAO COMBINADA =", MAPEcombinado, "%"))

```

Fonte: O autor, 2022