

GESTÃO DE PESSOAS EM NAVIOS DA ESQUADRA: UMA PROPOSTA DE  
MÉTODOS QUANTITATIVOS PARA A DISTRIBUIÇÃO DE VAGAS EM  
CURSOS PARA OS MILITARES QUE SERVEM EMBARCADOS, UTILIZANDO  
PROGRAMAÇÃO LINEAR INTEIRA, OPINIÃO DE ESPECIALISTA,  
SIMULAÇÕES ESTOCÁSTICAS E MEDIDAS DE RISCO

Daniel Villalva Martins

Dissertação de Mestrado apresentada ao  
Programa de Pós-graduação em Engenharia de  
Produção, COPPE, da Universidade Federal do  
Rio de Janeiro, como parte dos requisitos  
necessários à obtenção do título de Mestre em  
Engenharia de Produção.

Orientadores: Elton Fernandes

Juan Pablo Cajahuanca Luna

Rio de Janeiro  
Dezembro de 2025

GESTÃO DE PESSOAS EM NAVIOS DA ESQUADRA: UMA PROPOSTA DE  
MÉTODOS QUANTITATIVOS PARA A DISTRIBUIÇÃO DE VAGAS EM  
CURSOS PARA OS MILITARES QUE SERVEM EMBARCADOS, UTILIZANDO  
PROGRAMAÇÃO LINEAR INTEIRA, OPINIÃO DE ESPECIALISTA,  
SIMULAÇÕES ESTOCÁSTICAS E MEDIDAS DE RISCO

Daniel Villalva Martins

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO  
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA  
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS  
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM  
ENGENHARIA DE PRODUÇÃO.

Orientadores: Elton Fernandes

Juan Pablo Cajahuanca Luna

Aprovada por: Prof. Elton Fernandes

Prof. Roberto Ivo da Rocha Lima Filho

Prof. Leonardo Antonio Monteiro Pessôa

RIO DE JANEIRO, RJ – BRASIL

DEZEMBRO DE 2025

Martins, Daniel Villalva

Gestão de pessoas em navios da esquadra: uma proposta de métodos quantitativos para a distribuição de vagas em cursos para os militares que servem embarcados, utilizando programação linear inteira, opinião de especialista, simulações estocásticas e medidas de risco / Daniel Villalva Martins. – Rio de Janeiro: UFRJ/COPPE, 2025.

XII, 117 p.: il.; 29,7 cm.

Orientadores: Elton Fernandes

Juan Pablo Cajahuanca Luna

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia de Produção, 2025.

Referências Bibliográficas: p. 80-87.

1. Distribuição de vagas em cursos. 2. Programação linear inteira. 3. Séries temporais de contagem. 4. Otimização estocástica orientada a risco. 5. Marinha do Brasil. III. Título.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Produção (M.Sc.)

GESTÃO DE PESSOAS EM NAVIOS DA ESQUADRA: UMA PROPOSTA DE  
MÉTODOS QUANTITATIVOS PARA A DISTRIBUIÇÃO DE VAGAS EM  
CURSOS PARA OS MILITARES QUE SERVEM EMBARCADOS, UTILIZANDO  
PROGRAMAÇÃO LINEAR INTEIRA, OPINIÃO DE ESPECIALISTA,  
SIMULAÇÕES ESTOCÁSTICAS E MEDIDAS DE RISCO

Daniel Villalva Martins

Dezembro/2025

Orientadores: Elton Fernandes

Juan Pablo Cajahuanca Luna

Programa: Engenharia de Produção

Para que uma Marinha esteja pronta, é necessário não apenas dispor de meios tecnologicamente desenvolvidos, mas também de pessoas capacitadas para operá-los. Foi observado que a distribuição de vagas em cursos operativos comuns à tripulação dos navios não é apoiada em métodos quantitativos. Este trabalho propõe métodos para apoiar essa distribuição anual, para os militares embarcados em navios da Esquadra. Utiliza-se de séries mensais de 2020–2023 de uma amostra de 18 cursos comuns a três navios de um mesmo Esquadrão, integrando previsão de séries temporais de contagem com otimização estocástica orientada a risco e opinião de especialista. As séries são modeladas como processos de contagem do tipo random walk com termos Bernoulli–Poisson, gerando cenários de 12 meses validados por fan charts e julgamento de especialista. São formulados cinco modelos de programação linear inteira: determinístico; com buffer definido por especialista; e três estocásticos baseados em simulações e em Value at Risk (VaR) e Conditional Value at Risk (CVaR). Todos apresentaram custo global inferior à distribuição real. O modelo determinístico teve o melhor compromisso entre custo e cobertura; o modelo com buffer elevou o custo, mas acrescentou robustez; os modelos com VaR e CVaR foram mais eficientes em custo, porém com menor cobertura inicial. Nenhum curso ficou abaixo do índice mínimo nas distribuições sugeridas. Conclui-se que



os métodos são operacionalizáveis e reproduzíveis, permitindo calibrar risco e buffer para melhor atender às necessidades de capacitação a bordo e contribuir para a prontidão dos navios.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Production Engineering (M.Sc.)

PERSONNEL MANAGEMENT ABOARD FLEET SHIPS: A PROPOSAL OF  
QUANTITATIVE METHODS FOR ALLOCATING TRAINING COURSE SLOTS TO  
EMBARKED SERVICE MEMBERS, USING INTEGER LINEAR PROGRAMMING,  
EXPERT JUDGMENT, STOCHASTIC SIMULATIONS, AND RISK MEASURES

Daniel Villalva Martins

December/2025

Advisor: Elton Fernandes

Juan Pablo Cajahuanca Luna

Department: Production Engineering

For a Navy to be ready, it is necessary not only to have technologically advanced assets, but also qualified personnel to operate them. It has been observed that the allocation of vacancies in operational courses common to ship crews is not supported by quantitative methods. This work proposes methods to support this annual allocation for service members embarked on Fleet ships. Monthly series from 2020–2023 are used for a sample of 18 courses common to three ships from the same Squadron, integrating forecasting of count time series with risk-oriented stochastic optimization and expert opinion. The series are modeled as count processes of the random-walk type with Bernoulli–Poisson terms, generating 12-month scenarios validated by fan charts and expert judgment. Five integer linear programming models are formulated: a deterministic model; a model with a buffer defined by an expert; and three stochastic models based on simulations and on Value at Risk (VaR) and Conditional Value at Risk (CVaR). All of them yielded a global cost lower than that of the actual allocation. The deterministic model achieved the best trade-off between cost and coverage; the buffered model increased the cost but added robustness; the VaR- and CVaR-based models were more cost-efficient, but with lower initial coverage. No course fell below the minimum index in any of the suggested allocations. It is concluded that the methods are operationalizable and reproducible, allowing the calibration of risk and buffer to better meet on-board

training needs and contribute to the readiness of the ships.

## LISTA DE TABELAS

Tabela 1 – Modelo de controle de cursados .....	16
Tabela 2 – Vagas distribuídas em 2023 e custo por aluno .....	38
Tabela 3 – Estatísticas descritivas dos cursos do navio 1.....	39
Tabela 4 – Estatísticas descritivas dos cursos do navio 2.....	39
Tabela 5 – Estatísticas descritivas dos cursos do navio 3.....	40
Tabela 6 – Índices de dispersão e proporção de zeros.....	45
Tabela 7 - Vagas que faltaram para atingir o índice ideal no Navio 1 após a alocação, por curso e por tipo de distribuição. ....	66
Tabela 8 - Vagas que faltaram para atingir o índice ideal no Navio 2 após a alocação, por curso e por tipo de distribuição. ....	66
Tabela 9 - Vagas que faltaram para atingir o índice ideal no Navio 3 após a alocação, por curso e por tipo de distribuição. ....	66
Tabela 10 – Ranking dos modelos.....	70
Tabela 11 – Pontos fortes e limitações dos modelos .....	75
Tabela 12 – Verificação de estacionariedade (sem considerar a tendência) .....	106
Tabela 13 – Verificação da estacionariedade considerando a tendência.....	107
Tabela 14 – Vagas alocadas para o Navio 1 por tipo de distribuição.....	127
Tabela 15 – Vagas alocadas para o Navio 2 por tipo de distribuição.....	127
Tabela 16 – Vagas alocadas para o Navio 3 por tipo de distribuição.....	128
Tabela 17 – Índices após a alocação de vagas para o Navio 1 por tipo de distribuição. ....	128
Tabela 18 - Índices após a alocação de vagas para o Navio 2 por tipo de distribuição.	129
Tabela 19 - Índices após a alocação de vagas para o Navio 3 por tipo de distribuição.	129

## LISTA DE FIGURAS

Figura 1 - Fluxograma de solicitação e distribuição de vagas em cursos. Fonte: Elaborado pelo autor. ....	17
Figura 2 – Dados históricos Curso 12. ....	17
Figura 3 – Dados históricos Curso 18. ....	18
Figura 4 - Mapa estratégico da MB. Fonte: PEM 2040 .....	22
Figura 5 - EN e AEN da MB. Fonte: Adaptado do PEM 2040. ....	23
Figura 6 – Figura ilustrativa de VaR e CVaR. Fonte: Adaptado de Sarykalin et al. (2008). ....	33
Figura 7 – Análise exploratória Curso 12.....	41
Figura 8 – Gráficos de ACF/PACF para o Curso 12.....	44
Figura 9 – Simulações para o Curso 12.....	64
Figura 11 - Gráfico sobre atingimento do índice ideal nos cursos após a distribuição. ..	65
Figura 12 - Gráfico sobre o valor gasto na distribuição de vagas. ....	67
Figura 13 - Gráfico comparativo entre os valores que sobraram após a distribuição e os necessários para atingir os índices ideais restantes. ....	68
Figura 14 - Gráfico sobre valores que restaram após aplicação da sobra inicial para atingir os índices ideais restantes. ....	69
Figura 15 - Gráfico com o valor total necessário para que todos os cursos atinjam o índice ideal, considerando o valor gasto na distribuição somado ao valor necessário para atingir os índices ideais restantes. ....	70
Figura 16 – Análise exploratória do Curso 1.....	88
Figura 17 – Análise exploratória do Curso 2.....	89
Figura 18 – Análise exploratória do Curso 3.....	90
Figura 19 – Análise exploratória do Curso 4.....	91
Figura 20 – Análise exploratória do Curso 5.....	92
Figura 21 – Análise exploratória do Curso 6.....	93
Figura 22 – Análise exploratória do Curso 7.....	94
Figura 23 – Análise exploratória do Curso 8.....	95
Figura 24 – Análise exploratória do Curso 9.....	96
Figura 25 – Análise exploratória do Curso 10.....	97
Figura 26 – Análise exploratória do Curso 11.....	98
Figura 27 – Análise exploratória do Curso 12.....	99
Figura 28 – Análise exploratória do Curso 13.....	100

Figura 29 – Análise exploratória do Curso 14.....	101
Figura 30 – Análise exploratória do Curso 15.....	102
Figura 31 – Análise exploratória do Curso 16.....	103
Figura 32 – Análise exploratória do Curso 17.....	104
Figura 33 – Análise exploratória do Curso 18.....	105
Figura 34 – Gráficos de ACF/PACF para o Curso 1 .....	109
Figura 35 – Gráficos de ACF/PACF para o Curso 2.....	109
Figura 36 – Gráficos de ACF/PACF para o Curso 3.....	110
Figura 37 – Gráficos de ACF/PACF para o Curso 4.....	110
Figura 38 – Gráficos de ACF/PACF para o Curso 5.....	111
Figura 39 – Gráficos de ACF/PACF para o Curso 6.....	111
Figura 40 – Gráficos de ACF/PACF para o Curso 7.....	112
Figura 41 – Gráficos de ACF/PACF para o Curso 8.....	112
Figura 42 – Gráficos de ACF/PACF para o Curso 9.....	113
Figura 43 – Gráficos de ACF/PACF para o Curso 10.....	113
Figura 44 – Gráficos de ACF/PACF para o Curso 11.....	114
Figura 45 – Gráficos de ACF/PACF para o Curso 13.....	114
Figura 46 – Gráficos de ACF/PACF para o Curso 14.....	115
Figura 47 – Gráficos de ACF/PACF para o Curso 15.....	115
Figura 48 – Gráficos de ACF/PACF para o Curso 16.....	116
Figura 49 – Gráficos de ACF/PACF para o Curso 17.....	116
Figura 50 – Gráficos de ACF/PACF para o Curso 18.....	117
Figura 51 – Simulações para o Curso 1 .....	118
Figura 52 – Simulações para o Curso 2.....	118
Figura 53 – Simulações para o Curso 3.....	119
Figura 54 – Simulações para o Curso 4.....	119
Figura 55 – Simulações para o Curso 5.....	120
Figura 56 – Simulações para o Curso 6.....	120
Figura 57 – Simulações para o Curso 7.....	121
Figura 58 – Simulações para o Curso 8.....	121
Figura 59 – Simulações para o Curso 9.....	122
Figura 60 – Simulações para o Curso 10.....	122
Figura 61 – Simulações para o Curso 11 .....	123
Figura 62 – Simulações para o Curso 13.....	123

Figura 63 – Simulações para o Curso 14.....	124
Figura 64 – Simulações para o Curso 15.....	124
Figura 65 – Simulações para o Curso 16.....	125
Figura 66 – Simulações para o Curso 17.....	125

## SUMÁRIO

<b>LISTA DE TABELAS.....</b>	<b>viii</b>
<b>LISTA DE FIGURAS.....</b>	<b>ix</b>
<b>1 INTRODUÇÃO .....</b>	<b>14</b>
1.1 CONTEXTUALIZAÇÃO .....	14
1.2 FORMULAÇÃO DO PROBLEMA .....	16
1.3 JUSTIFICATIVA .....	18
1.4 OBJETIVOS .....	19
1.5 ESTRUTURA DA DISSERTAÇÃO.....	20
<b>2 REFERENCIAL TEÓRICO .....</b>	<b>21</b>
2.1 PLANEJAMENTO ESTRATÉGICO DE RECURSOS HUMANOS .....	21
2.2 PREVISÃO DE DEMANDA .....	24
<b>2.2.1 Séries Temporais de Dados de Contagem .....</b>	<b>24</b>
2.3 PESQUISA OPERACIONAL – PROGRAMAÇÃO LINEAR INTEIRA .....	28
2.4 MEDIDAS DE RISCO: VAR E CVAR .....	30
2.5 OPINIÃO DE ESPECIALISTA .....	34
<b>3 METODOLOGIA.....</b>	<b>37</b>
3.1 CLASSIFICAÇÃO DA PESQUISA .....	37
3.2 COLETA DOS DADOS .....	37
3.3 ANÁLISE EXPLORATÓRIA DOS DADOS .....	38
3.4 COLETA DA OPINIÃO DO ESPECIALISTA .....	46
3.5 MODELAGEM PARA SIMULAÇÃO .....	48
3.6 VALIDAÇÃO DAS SIMULAÇÕES .....	53
3.7 MODELAGEM DA DISTRIBUIÇÃO DE VAGAS .....	53
<b>3.7.1 Modelo 1: PLI .....</b>	<b>54</b>
<b>3.7.2 Modelo 2: PLI + Buffer (Opinião de Especialista) .....</b>	<b>55</b>
<b>3.7.3 Modelo 3: PLI + Simulações Estocásticas + <i>VaR</i>0.71 .....</b>	<b>56</b>



3.7.4 Modelo 4: PLI + Simulações Estocásticas + $VaR0.90$ .....	58
3.7.5 Modelo 5: PLI + Simulações Estocásticas + $CVaR$ .....	59
<b>4 RESULTADOS</b> .....	<b>63</b>
4.1 RESULTADOS DAS PREVISÕES .....	63
4.2 RESULTADOS DOS MODELOS OTIMIZADOS .....	64
4.3 ANÁLISE DE CUSTO .....	67
<b>5 DISCUSSÃO</b> .....	<b>71</b>
5.1 INTERPRETAÇÃO DOS RESULTADOS.....	71
5.2 PONTOS FORTES E LIMITAÇÕES DOS MODELOS.....	72
5.2.1 Modelo 1: PLI .....	72
5.2.2 Modelo 2: PLI + Buffer (Opinião de Especialista).....	72
5.2.3 Modelo 3: PLI + Simulações Estocásticas + $VaR0.71$ .....	73
5.2.4 Modelo 4: PLI + Simulações Estocásticas + $VaR0.90$ .....	73
5.2.5 Modelo 5: PLI + Simulações Estocásticas + $CVaR$ .....	73
5.3 OBSERVAÇÕES SOBRE OS DADOS COLETADOS .....	76
<b>6 CONCLUSÕES</b> .....	<b>78</b>
6.1 SÍNTESE DOS OBJETIVO ATINGIDOS.....	78
6.2 CONTRIBUIÇÕES PARA A MARINHA.....	79
6.3 SUGESTÕES PARA TRABALHOS FUTUROS .....	79
<b>REFERÊNCIAS</b> .....	<b>80</b>
<b>APÊNDICE A – ANÁLISE EXPLORATÓRIA DOS CURSOS</b> .....	<b>88</b>
<b>APÊNDICE B – TESTES DE ESTACIONARIEDADE</b> .....	<b>106</b>
<b>APÊNDICE C – GRÁFICOS DE ACF/PACF DOS CURSOS</b> .....	<b>109</b>
<b>APÊNDICE D – SIMULAÇÕES DOS CURSOS</b> .....	<b>118</b>
<b>APÊNDICE E – VAGAS ALOCADAS POR TIPO DE DISTRIBUIÇÃO</b> .....	<b>127</b>

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO

O mar tem uma grande importância para o Brasil, nele se encontra a Amazônia Azul, que é a região marítima brasileira composta pela superfície do mar, águas sobrejacentes ao leito, solo e subsolo marinho, na extensão do Oceano Atlântico que se projeta do litoral até o limite exterior da Plataforma Continental do Brasil. Ela recebe esse nome por sua relevância estratégica, econômica e ambiental, similar a floresta amazônica em terra. A sua importância para o país é devido aos seguintes fatores (MARINHA DO BRASIL, 2025):

- a) **Comércio exterior:** Mais de 95% das exportações e importações brasileiras ocorrem nessa área, sendo primordial para o escoamento da produção nacional.
- b) **Energia:** É a região onde cerca de 95% do petróleo nacional e grande parte do gás natural são extraídos.
- c) **Recursos naturais:** Abriga diversos recursos minerais, pesqueiros e biodiversidade marinha, além de centros industriais e energéticos.
- d) **Soberania:** É considerada patrimônio nacional, sob constante proteção, monitoramento e controle para enfrentar ameaças e garantir o uso sustentável, de acordo com diretrizes estratégicas da Marinha do Brasil.
- e) **Vertentes:** Deve ser vista por quatro vertentes fundamentais: econômica, científica, ambiental e de soberania.

Portanto, a Amazônia Azul é essencial para o desenvolvimento econômico, pesquisa científica, preservação ambiental e garantia da soberania nacional do país. Seu papel é estratégico e demanda vigilância ativa e exploração sustentável para o presente e futuro do Brasil. Neste contexto, a Marinha do Brasil (MB), como sentinela dos mares, desempenha um papel fundamental na proteção e no aproveitamento desses recursos (SANTOS et al., 2022).



Figura 1 – Ilustração do tamanho da Amazônia Azul. Fonte: Rolim (2025).

Os navios da MB, no entanto, não são apenas estruturas físicas navegando pelos mares, eles são sistemas complexos que requerem operação e manutenção por parte de pessoas altamente capacitadas. Segundo Holden (2005), o navio pode ser considerado um grande organismo formado por diversos sistemas, que por sua vez trabalham de forma a se complementarem, suprimindo funções necessárias ao funcionamento dos demais, logo, a tripulação de um navio é tão importante quanto a própria embarcação. Cada membro da tripulação desempenha um papel vital, desde a manutenção dos sistemas de bordo até a tomada de decisões que podem impactar no cumprimento de uma missão.

Nesse sentido, a capacitação das pessoas que trabalham a bordo dos navios é de suma importância, pois o sucesso das operações navais depende diretamente do nível de

habilidade e conhecimento da tripulação. Além disso, a capacitação adequada pode além de aumentar a segurança das operações, reduzir erros e evitar acidentes (SÁNCHEZ-BEASKOETXEA, 2021).

## 1.2 FORMULAÇÃO DO PROBLEMA

Uma das etapas do processo de qualificação do pessoal que serve a bordo dos navios é através de cursos realizados em centros de instrução da própria MB. Na gestão interna de cada navio, há um documento chamado ‘mapa de cursados’ que controla esse processo, listando todos os cursos necessários para o pessoal embarcado. Para cada curso, há um índice mínimo a ser mantido e um índice ideal a ser atingido, e esse valor é referente a quantidade de pessoas com aquele respectivo curso. Mensalmente cada navio envia esse documento, em formato de planilha eletrônica, para o Esquadrão ao qual está subordinado, indicado o índice atual para cada um dos cursos. Abaixo está um exemplo ilustrativo do *layout* do mapa de cursados:

Tabela 1 – Modelo de controle de cursados

Curso	Índice ideal	Índice mínimo	Índice atual
Curso 1	3	1	2
Curso 2	20	10	7
...	...	...	...
Curso n	10	5	12

O processo de distribuição de vagas em cursos segue o seguinte trâmite: os navios enviam ao Esquadrão subsídios de necessidades de vagas em cursos para o ano seguinte, o Esquadrão compila os dados, os analisa, e faz uma solicitação ao Comando de Força que está subordinado. No ano seguinte, o Esquadrão recebe as vagas dos cursos deste Comando de Força e as distribui para os navios subordinados. O processo está ilustrado abaixo:

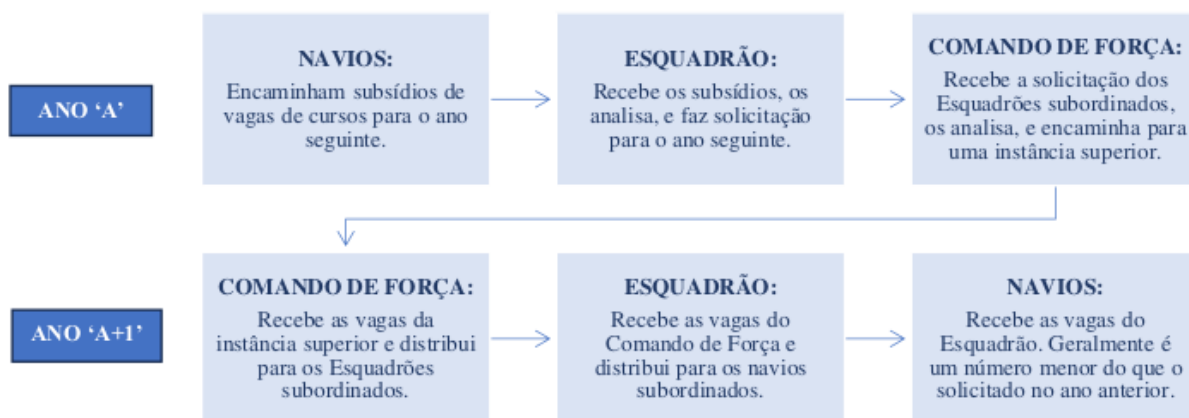


Figura 2 - Fluxograma de solicitação e distribuição de vagas em cursos. Fonte: Elaborado pelo autor.

Um ponto a se notar, é que foi observado que a distribuição de vagas em cursos não tem ocorrido da melhor forma possível, ocorrendo alguns casos de navios com a quantidade de cursados abaixo do índice ideal em alguns cursos, e acima do índice ideal em outros cursos, ambos ocorrendo às vezes por períodos prolongados. Isso foi observado juntamente com um especialista da área que é responsável pela distribuição das vagas para os navios, ao serem gerados gráficos referentes ao período dos dados disponibilizados por ele. Abaixo encontra-se uma análise comparativa em 2 cursos em que essas observações foram consideradas mais significativas, de dados observados de 2020 a 2023 para 3 navios do mesmo Esquadrão:




Figura 3 – Dados históricos Curso 12.




Figura 4 – Dados históricos Curso 18.

Durante a pesquisa, foi observado que não havia um processo baseado em métodos quantitativos para a distribuição de vagas aos navios subordinados, sendo o processo totalmente realizado de forma subjetiva. Com base nos elementos apresentados, as seguintes perguntas guiaram o problema de pesquisa deste estudo:

- Como otimizar a distribuição anual de vagas, assegurando que índices mínimos e ideais sejam respeitados de forma eficiente?
- Que métricas e medidas de risco podem contribuir para maior robustez nas decisões de alocação de vagas?

### 1.3 JUSTIFICATIVA

O não atingimento dos índices ideais ou a manutenção dos mínimos em determinados cursos, por períodos prolongados, mesmo após novas distribuições de vagas, evidencia uma necessidade de se reavaliar o processo de distribuição de vagas para os navios, observando-se os fatores que têm contribuído para o não atingimento desses índices.

Levando-se em consideração que o orçamento da Marinha é limitado, e que cada um dos cursos destinados aos navios possui um custo, torna-se necessário a otimização do processo de distribuição. Isso está relacionado com uma alocação adequada de vagas, de forma a assegurar o atendimento das necessidades de conhecimento operativo da melhor forma possível. Segundo Tomaz e Tomaz (2023), uma gestão estratégica de

pessoal é um elemento de extrema relevância para o sucesso de qualquer organização, e na MB não seria diferente.

Sob a perspectiva do navio, os resultados deste trabalho podem culminar em uma melhor preparação e desempenho dos militares que servem embarcados, contribuindo para uma melhor condição de eficiência do navio. Militares bem treinados e capacitados têm maior probabilidade de desempenhar melhor suas funções, e com maior precisão, o que é aspecto essencial para as operações de um navio de guerra.

Para a instituição, a pesquisa pode contribuir para a identificação de lacunas e oportunidades de melhoria no processo de capacitação dos militares, possibilitando um ajuste e refino do atual processo de gestão de vagas em cursos. Assim, garante-se que eles adquiram as habilidades necessárias para cumprir suas funções da melhor forma. Isso aumentará a eficiência geral da MB, além de aplicar os recursos de uma forma mais eficiente.

Uma boa gestão da capacitação dos militares embarcados é fundamental para o funcionamento adequado e a efetividade das operações navais. Então, uma pesquisa que analisa e otimiza esse processo, poderá garantir que a MB esteja mais adequadamente preparada e treinada para enfrentar os possíveis desafios e ameaças. Isso contribui para a segurança e o sucesso das missões da Marinha, trazendo benefícios significativos para a sociedade, no que tange à segurança nacional e no atendimento dos interesses do país.

Diante exposto, ao transformar um processo hoje subjetivo em um procedimento quantitativo reproduzível, a pesquisa contribui para elevar a prontidão dos navios do ponto de vista da capacitação de pessoal que serve embarcado.

## 1.4 OBJETIVOS

Geral: Propor um modelo de otimização a ser aplicado na distribuição das vagas.

Específicos:

- a) Desenvolver e aplicar modelos de Programação Linear Inteira (PLI) para a distribuição de vagas.
- b) Incorporar opinião de especialistas e medidas de risco, Percentil, Value-at-Risk (VaR) e Conditional Value-at-Risk (CVaR), para aumentar a robustez das soluções.
- c) Comparar os resultados dos modelos propostos com a distribuição real, considerando eficiência no atingimento dos índices, complementando com uma análise de custo.

- d) Identificar lacunas ou áreas de melhorias nas práticas atuais de gestão das vagas em cursos para o pessoal que serve embarcado.

## 1.5 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está organizada em seis capítulos, sendo estes distribuídos da seguinte forma:

O Capítulo 1 apresenta a introdução com contextualização do assunto, iniciando com a importância do mar para o Brasil, e a importância da MB na defesa das riquezas provenientes dele. É exposto o problema de pesquisa, questões centrais, justificativa, além dos objetivos gerais e específicos.

O Capítulo 2 apresenta o referencial teórico com os conceitos acadêmicos que fundamentam a pesquisa. Aborda temas de planejamento estratégico, previsão de demanda, séries temporais de contagem e programação linear inteira, incluindo opinião de especialista e medidas de risco.

O Capítulo 3 apresenta a metodologia com a classificação da pesquisa e o estudo de caso realizado, além da coleta de dados dos cursos e navios analisados. É descrita a modelagem das simulações baseadas em séries temporais de dados de contagem, além da formulação de cinco modelos de programação inteira.

O Capítulo 4 apresenta os resultados obtidos das simulações e dos modelos de otimização propostos, do ponto de vista do atingimento de índices nos cursos, das sobras de vagas, e dos recursos empregados em cada um dos diferentes tipos de distribuição.

O Capítulo 5 apresenta a discussão com a interpretação e crítica dos resultados obtidos através dos modelos, comparando-os com a distribuição real que ocorreu, além comentar vantagens e desvantagens de cada um. Discute aspectos observados na qualidade dos dados coletados e suas implicações na interpretação dos modelos.

O Capítulo 6 apresenta as conclusões com a síntese dos objetivos alcançados, evidenciando as contribuições da pesquisa para gestão da capacitação do pessoal que serve embarcado, incluindo a expansão para demais navios, além de sugerir trabalhos futuros.



## 2 REFERENCIAL TEÓRICO

Para a atingimento dos objetivos desta pesquisa, serão apresentados trabalhos que estejam relacionados aos temas de planejamento estratégico de recursos humanos, previsão de demanda, otimização através de Programação Linear Inteira, além das medidas de risco e opinião de especialista na gestão dos processos. Isso tem por objetivo estabelecer uma base conceitual para justificar a escolha dos métodos propostos para a resolução do problema apresentado nos cursos operativos da MB.

### 2.1 PLANEJAMENTO ESTRATÉGICO DE RECURSOS HUMANOS

O planejamento estratégico é uma ferramenta de grande importância nas organizações, tanto privadas como públicas. Ferigato e Rosini (2021) verificam como a gestão de pessoas, com foco em planejamento estratégico, pode melhorar a produtividade, os resultados e o posicionamento de mercado de uma empresa, sendo essencial para a gestão organizacional ao orientar políticas, estratégias e objetivos de curto e longo prazo. Apesar de isso ser uma prática mais comumente vista no setor privado, Tomaz e Tomaz (2023) abordam a importância do treinamento e do desenvolvimento na gestão estratégica de pessoas na administração pública. Os autores afirmam que o setor público, apesar de não visar lucros, ao investir no capital humano, proporcionará as organizações a obterem funcionários mais preparados e qualificados, melhorando a produtividade, a eficiência e a qualidade na prestação de serviços ao cidadão.

A MB possui o Plano Estratégico da Marinha para 2040 (PEM 2040) um documento de alto nível de acesso público que foi elaborado para orientar o seu planejamento de médio e longo prazo. Este plano é estruturado a partir da análise do ambiente operacional e da identificação de ameaças, estabelecendo programas estratégicos com o objetivo de prover o Brasil com uma Força Naval moderna e de dimensão compatível com a estatura político-estratégica do país (MARINHA DO BRASIL, 2020).

O PEM 2040 visa contribuir para a defesa da pátria e a salvaguarda dos interesses nacionais, tanto no mar quanto em águas interiores. O plano detalha Objetivos Navais (OBNAV), organizados em uma cadeia de valores, que culminam no cumprimento da Missão da MB e no atingimento da Visão de Futuro da MB até 2040.

No documento é apresentado um mapa estratégico, onde são listados os OBNAV a serem cumpridos. Estes são distribuídos em três perspectivas (institucional, processos

e resultados para a sociedade), onde os que estão nos patamares inferiores, de forma geral, contribuem para que seja possível cumprir os OBNAV dos superiores. Na figura abaixo é apresentado o mapa estratégico, com destaque para o OBNAV 11 que será abordado nessa pesquisa.

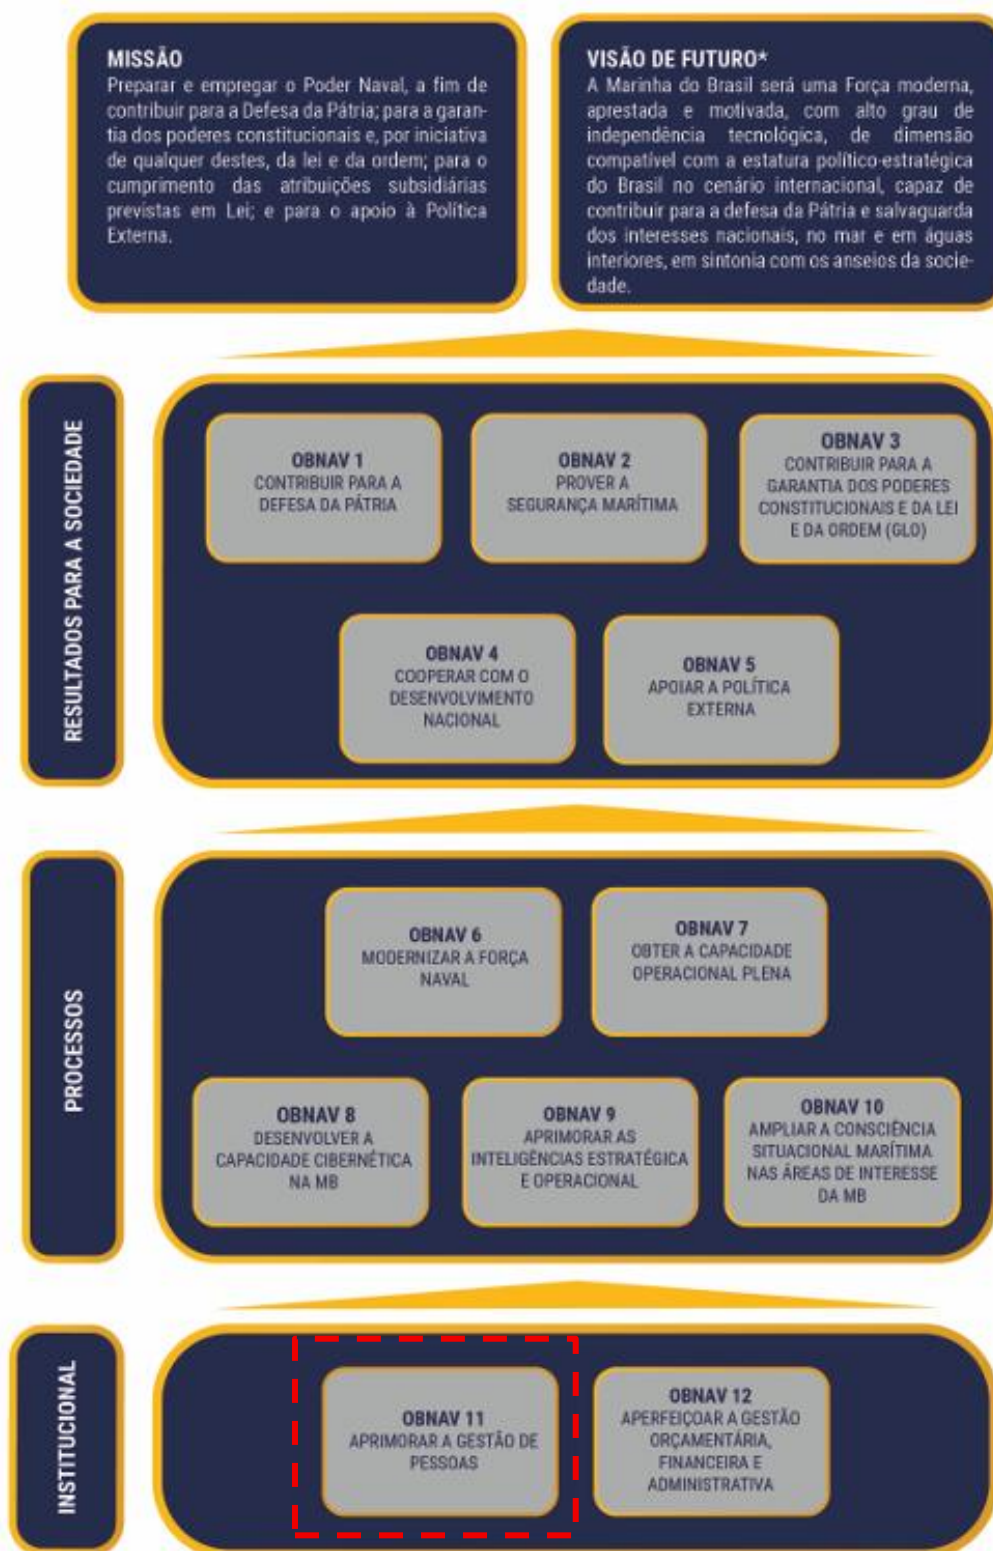


Figura 5 - Mapa estratégico da MB. Fonte: PEM 2040

Os OBNAV são definidos como o ‘o que’ deve ser feito para se alcançar a missão e a visão de futuro da MB. Dentro deles existem as Estratégias Navais (EN), que são ‘como’ devem ser feitos os OBNAV, e dentro de cada EN existem as Ações de Estratégia Naval (AEN), que adequam as EN em ações concretas para a realidade do país, levando-se em consideração o orçamento, a tecnologia, a disponibilidade de matéria-prima e capacitação (MARINHA DO BRASIL, 2020). Dentro do OBNAV 11, ‘Aprimorar a Gestão de Pessoas’, existe a EN 11, ‘Pessoal – Nosso Maior Patrimônio’, e por seguinte, das AEN apresentadas, há a AEN – Pessoal -2 ‘Aprimorar a capacitação de pessoal da MB’, conforme ilustrado abaixo:

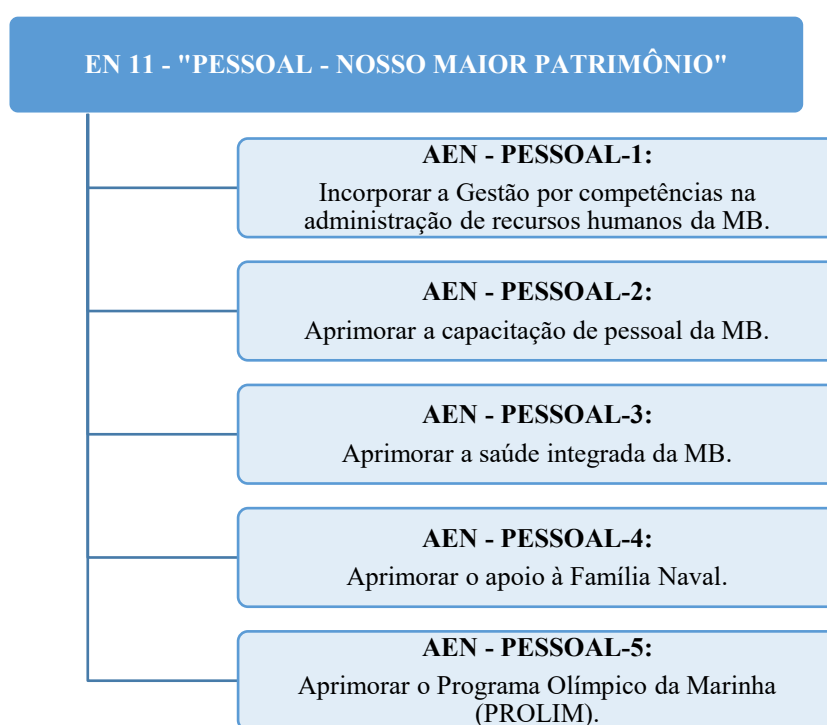


Figura 6 - EN e AEN da MB. Fonte: Adaptado do PEM 2040.

Segundo o PEM-2040, no que tange ao OBNAV-11 Aprimorar a gestão de Pessoas, a EN-11 visa “aperfeiçoar os sistemas e os procedimentos relacionados à gestão de pessoal, a fim de prover à Força a pessoa certa, com a capacitação adequada, no lugar e momentos certos, visando ao cumprimento da Missão da MB.” (MARINHA DO BRASIL, 2020).

Nesse sentido, foi observado que a MB possui uma diretriz clara sobre aprimorar a capacitação de pessoas em seu mapa estratégico, porém notou-se que ainda há uma carência de métodos quantitativos que traduzam o PEM 2040 em práticas de gestão dos

cursos para o pessoal que serve embarcado, pelo menos no nível Esquadrão-navios. Isso justifica este trabalho, pois ele oferecerá uma ligação entre o planejamento estratégico qualitativo e a execução prática quantitativa.

## 2.2 PREVISÃO DE DEMANDA

Uma das formas de contribuir para a distribuição otimizada, seria tentar compreender qual seria a quantidade de cursados ou necessidades de vagas para o futuro. A previsão de demanda é comumente empregada no processo decisório de várias organizações, sendo vista como uma etapa fundamental, pois possibilita visualizar necessidades futuras, além de permitir realizar ajustes na alocação de recursos de uma forma mais eficiente.

De acordo com Ackermann e Sellitto (2022), a previsão de demanda está presente em várias empresas, com diferentes portes e setores, sendo isso uma prática considerada essencial para o planejamento estratégico e operacional delas, possibilitando antecipar as suas necessidades. Petropoulos et al. (2022) afirmam que o intuito da previsão é melhorar a tomada de decisão em cenários em que haja incerteza, usando os dados históricos como subsídios para a realização de escolhas mais eficientes sobre o futuro. Para o contexto militar, que é um setor público, esse assunto é muito relevante, tendo em vista que os recursos costumam ser escassos, e decisões ruins podem comprometer a execução de tarefas específicas desse setor.

### 2.2.1 Séries Temporais de Dados de Contagem

Uma série temporal é o conjunto de observações realizadas por um período, em intervalos regulares, para entender os padrões dos dados históricos e possibilitar projetar novos valores (ENDERS, 2015; HYNDMAN e ATHANASOPOULOS, 2021), e a sua análise é uma abordagem adequada para projeções de curto prazo (ACKERMANN e SELLITTO, 2022). No caso da pesquisa, trata-se de séries temporais de dados de contagem, pois é uma sequência de números inteiros não-negativos, registrados em intervalos de tempo igualmente espaçados, onde cada valor representa uma contagem referente a quantidade de cursados no mês (FOKIANOS, 2012; WEISS, 2018).

Esses tipos de séries possuem as seguintes características (DAVIS et al., 2021):

- a) Valores inteiros não negativos (contagens): os dados assumem apenas valores inteiros maiores ou iguais a zero;

- b) Dependência temporal: as observações vizinhas são correlacionadas, pois resultam de mecanismos de geração de contagem que atuam ao longo do tempo;
- c) Sobredispersão: a variância frequentemente excede a média, apresentado séries sobredispersas (*overdispersed*);
- d) Inflação de zeros (*zero-inflation*): muitas vezes, há mais contagens iguais a zero (*zero counts*) do que o que pode ser explicado pelas distribuições marginais de contagem clássicas, como a Poisson, binomial ou binomial negativa;
- e) Autocorrelações predominantemente não negativas: é comum que as autocorrelações de primeira ordem sejam positivas.

Inicialmente, McKenzie (1985) e Alzaid e Al-Osh (1987) apresentaram o modelo *Integer-valued Autoregressive* de primeira ordem – INAR(1), contraponto os modelos autorregressivos tradicionais para dados contínuos, com a seguinte formulação básica:

$$X_t = \alpha \circ X_{t-1} + \varepsilon_t \quad (1)$$

Em que  $X_t$  representa o valor da série no tempo  $t$ ,  $\alpha \in (0, 1)$  é o parâmetro autorregressivo e  $\varepsilon_t$  é o termo de inovação com valores inteiros não negativos. Ela foi baseada no operador *thinning* binomial, introduzido por Steutel e Van Harn (1979), representado pelo símbolo  $\circ$ . Ele substitui a multiplicação escalar tradicional por uma operação que preserva a natureza inteira dos dados, mediante a verificação da manutenção da variável aleatória de contagem  $X$  de forma probabilística, pois nos modelos tradicionais, após alguma multiplicação escalar podem ser gerados valores não inteiros.

A estacionariedade costuma ser uma condição central em grande parte da teoria clássica de séries temporais, pois garante que as propriedades estatísticas da série, como média, variância e autocorrelação permaneçam constantes ao longo do tempo, facilitando a modelagem, a inferência e a previsão (DAVIS et al., 2021), porém há séries que não apresentam estacionariedade. Ryan et al. (2025) discutem que processos como o passeio aleatório (*Random Walk* - RW) ou séries com tendência podem invalidar testes e procedimentos construídos sob a hipótese de estacionariedade, exigindo transformações ou modelos específicos para lidar com essas estruturas. Assim, identificar corretamente o tipo de não estacionariedade é importante para escolher uma modelagem adequada.

Além disso, é importante observar a quantidade de dados históricos necessários, que no caso deste estudo são de 48 observações. Hyndman e Kostenko (2007) abordam

sobre a questão de quantas observações são necessárias para modelos estatísticos de previsão sazonal, enfatizando que a resposta depende muito do tipo de modelo utilizado e da quantidade de variação aleatória presente nos dados. Segundo os autores, embora a regra geral seja usar "o máximo possível" de dados históricos e relevantes, o estudo documenta os requisitos mínimos teóricos de tamanho de amostra, que são alcançados apenas se a variação aleatória nos dados for muito pequena. Estatisticamente, os autores dizem que é sempre necessário ter mais observações do que parâmetros (coeficientes) para que os intervalos de previsão não sejam infinitamente amplos. No entanto, a aleatoriedade é o fator mais importante, tornando os requisitos mínimos insuficientes na prática. Os autores concluem que para estimar um modelo com precisão sob alta variação aleatória, é necessário ter substancialmente mais dados do que o mínimo teórico, e quando os dados são escassos, é aconselhável complementar com informações externas, como séries temporais análogas ou opinião de especialistas.

A previsão também é afetada pelo tamanho amostral, pois em um estudo realizado por Pincheira e Medel (2016), foi investigado o problema de previsão de séries temporais estacionárias e altamente persistentes, como a inflação mensal, diante da limitação amostral e da elevada incerteza na estimação dos parâmetros dos modelos tradicionais. Nele, os autores compararam o desempenho de modelos simples de RW sem tendência com alternativas autoregressivas (ARIMA e SARIMA) por meio de simulações e testes empíricos com os índices de preços ao consumidor do Canadá, Suécia, Suíça, Reino Unido e Estados Unidos, em diferentes tamanhos de janela amostral. Os resultados mostraram que, em amostras pequenas ou moderadas e em horizontes de previsão mais longos, as previsões obtidas pela RW sem tendência podem ser superiores às de modelos mais complexos, mesmo quando a raiz unitária é rejeitada nos testes clássicos. Os autores concluíram que, sob alta persistência e forte restrição amostral, abordagens simples podem ser não apenas eficientes, mas também robustas para fins de previsão, devido ao menor impacto da incerteza paramétrica sobre o erro de previsão.

Imoro et al. (2020) investigaram a queda e a instabilidade nas matrículas do curso de Estatística do *Bolgatanga Polytechnic* (Gana), no período de 2003 e 2019, utilizando modelos de séries temporais determinísticos e estocásticos. Os resultados mostraram que a série de matrículas apresenta variações altamente imprevisíveis, sendo mais bem modelada por um RW, especificamente através do modelo ARIMA(0,4,0), que indica ausência de tendência robusta e forte influência de choques aleatórios passados. Os autores concluíram que o fenômeno das matrículas se caracteriza por elevada

aleatoriedade e que, sem intervenções estruturais ou institucionais, o risco de estagnação ou queda persistente no número de alunos permanece elevado.

Segundo Davis et al. (2021), em séries de contagem não há um modelo universalmente dominante, ao contrário das séries Gaussianas estacionárias onde os modelos autoregressivos de média móvel são o principal veículo de modelagem. Segundo os autores, a literatura evoluiu de forma *ad hoc*, com diferentes classes de modelos sendo desenvolvidas para situações específicas.

Após a confecção do modelo que melhor representa o comportamento dos dados, a fim de que sejam realizadas simulações de possíveis cenários, é importante que haja o processo de validação desse modelo. Sargent (2020), estipula 8 passos para validação de simulações:

- 1- Um acordo deve ser feito antes do desenvolvimento do modelo, especificando a abordagem de decisão e um conjunto de técnicas específicas de validação a serem usadas;
- 2- Especificar a faixa aceitável de precisão exigida das variáveis de saída do modelo que são de interesse para a aplicação pretendida;
- 3- Testar, sempre que possível, as premissas e teorias subjacentes ao modelo de simulação;
- 4- Em cada iteração do modelo, realizar pelo menos a validação de face no modelo conceitual;
- 5- Em cada iteração do modelo, pelo menos explorar o comportamento do modelo de simulação utilizando o modelo computacional;
- 6- Na última iteração do modelo, fazer comparações, se possível, entre o modelo de simulação e os dados reais de comportamento do sistema (saída) para pelo menos alguns conjuntos de condições experimentais;
- 7- Preparar a documentação de Verificação e Validação para inclusão na documentação geral do modelo de simulação;
- 8- Se o modelo de simulação for utilizado por um período prolongado, elaborar um cronograma para a revisão periódica da validade dele.

Em suma, levando-se em consideração o tamanho da amostra e a aleatoriedade dos dados, a opção por um modelo mais simples e parcimonioso é preferível, devendo ser

seguido do processo de validação mais aplicável. Isso possibilitará a geração de previsões que auxiliarão no processo de otimização da distribuição de vagas.

### 2.3 PESQUISA OPERACIONAL – PROGRAMAÇÃO LINEAR INTEIRA

Em situações de alocação de recursos, como vagas de cursos, decisões baseadas apenas em valores médios podem não refletir as necessidades e restrições operacionais reais. A Programação Linear Inteira (PLI) ou Programação Inteira (PI), garante soluções viáveis ao capturar indivisibilidades e exigências lógicas. Assim, a Pesquisa Operacional (PO) oferece um arcabouço robusto para modelar e resolver problemas concretos como o da capacitação naval.

Segundo Belfiore e Fávero (2012) a Pesquisa Operacional (PO) teve origem na Inglaterra durante a Segunda Guerra Mundial com o intuito de resolver questões logísticas, táticas e estratégicas militares, quando um grupo de cientistas foi convocado para determinar a utilização mais eficaz dos recursos militares limitados, marcando assim a primeira atividade formal desse campo de estudo. Esta é uma área da matemática aplicada que utiliza modelos matemáticos e algoritmos para auxiliar na tomada de decisões. No caso de variáveis inteiras, como é o caso da pesquisa, as vagas que precisam ser alocadas sempre serão números inteiros, logo a PLI é a ferramenta ideal para a obtenção da solução ótima, que geralmente é caracterizada por:

- a) Variáveis de decisão: são as escolhas que serão feitas, que na pesquisa estão representadas pelas vagas alocadas a cada navio e cada curso;
- b) Parâmetros: são valores fixos conhecidos, como o índice dos cursos, quantidade de vagas a serem distribuídas e os valores dos cursos;
- c) Função objetivo: é o critério de otimização, sendo de minimização ou maximização, que na pesquisa será minimização de desvios em relação ao índice ideal; e
- d) Restrições: são os limites estabelecidos, como o cumprimento índices dos cursos e a limitação do total de vagas a serem alocadas.

A formulação geral de um problema de PLI pode ser escrita como:

$$\text{Minimizar } z = \sum_{i=1}^n c_i x_i \quad (2)$$



$$\text{sujeito a } \sum_{i=1}^n a_{ji}x_i \leq b_j, \quad j = 1, \dots, m \quad (3)$$

$$x_i \in \mathbb{Z}, \quad i = 1, \dots, n \quad (4)$$

Onde:

- $x_i$  são as variáveis de decisão;
- $c_i$  são coeficientes da função objetivo;
- $a_{ji}$  são os coeficientes das restrições; e
- $b_j$  são os limites de cada restrição.

Pujari et al. (2021) exploram técnicas de PO na tomada de decisões em Gestão de Recursos Humanos (GRH) em diversas organizações. Os autores argumentam que as decisões de RH frequentemente carecem de objetividade e estrutura, o que pode ser resolvido através da introdução de modelos quantitativos de PO. O estudo foca em três técnicas: Programação Linear, Problemas de Atribuição (*Assignment Problems*) e Simulação de Sistemas, explicando como elas podem otimizar processos de GRH, como recrutamento, treinamento e alocação de tarefas, ao minimizar custos e maximizar a eficiência. O estudo mostra uma interdependência clara e uma estrutura confiável para a tomada de decisões em RH utilizando a PO, concluindo que ela oferece objetividade e racionalidade para a GRH.

Yamavaram et al. (2022) apresentam aplicações de PO no contexto militar, com métodos de otimização e modelagem que têm sido utilizados em diferentes forças armadas ao redor do mundo. Os autores destacam que há inúmeras oportunidades de otimização apoiadas pelos métodos de PO, dentre eles estão modelos empregando a PLI aplicados ao escalonamento de tripulações e à distribuição de munições, e os modelos estocásticos, como Cadeias de Markov e simulações, empregados na previsão de efetivos e planejamento de treinamentos. Isso demonstra a relevância dessas técnicas matemáticas e probabilísticas para lidar com problemas de alocação de recursos, planejamento estratégico e tomada de decisão em ambientes complexos e sujeitos a riscos, que comuns no contexto militar.

Odion et al. (2023) apresentam uma aplicação da Programação Inteira Mista (MIP) na otimização da alocação de recursos de treinamento militar na Nigerian Defence Academy (NDA), de modo a minimizar o custo total sem comprometer a proficiência exigida dos cadetes. Os autores desenvolveram um modelo que buscou minimizar os

custos associados ao treinamento, assegurando que os cadetes atingissem níveis mínimos dos requisitos em tarefas consideradas essenciais. Os resultados obtidos demonstraram que esse tipo de abordagem permitiu reduzir significativamente os custos do processo de treinamento, sem comprometer a qualidade e a eficácia da formação, evidenciando o potencial da modelagem de otimização como instrumento de apoio à tomada de decisão naquele programa de treinamento militar.

Hausken (2024) apresenta uma revisão sobre os cinquenta anos do uso de PO em defesa, mostrando como ela é extremamente útil nessa área, por aplicar técnicas matemáticas e de otimização para auxiliar na tomada de decisões complexas em contextos de conflito, segurança e risco. Segundo o autor, o objetivo da PO na defesa é fornecer análises rigorosas e *insights* para a alocação ótima de recursos e para a escolha das melhores estratégias, em face de ameaças intencionais e não intencionais, tornando-a uma ferramenta fundamental para a segurança e a resiliência de sistemas críticos.

A PO é um assunto conhecido e consolidado na literatura acadêmica, e tem mostrado a sua eficiência de diferentes formas e em diferentes ambientes e aplicações. O seu uso nessa pesquisa trará grandes benefícios do ponto de vista de otimização e alocação de recursos escassos, que no caso são referentes a alocação de vagas em cursos.

## 2.4 MEDIDAS DE RISCO: VAR E CVAR

Em problemas de alocação de recursos limitados, às vezes escassos, e em ambientes de incertezas como a distribuição de vagas de cursos, as decisões baseadas em valores esperados talvez não sejam suficientes. Apesar dos modelos determinísticos oferecerem soluções ótimas, eles não consideram o tamanho das perdas em cenários adversos. Na administração naval, uma capacitação abaixo do mínimo esperado pode comprometer a prontidão operacional, logo, torna-se necessário avaliar não somente aquilo que é esperado, mas também os piores cenários possíveis.

Em problemas de otimização sob incerteza, a inclusão de medidas de risco é um fator importante no apoio a tomada de decisão. Duas medidas de risco conhecidas na literatura são o Value-at-Risk (VaR) e o Conditional Value-at-Risk (CVaR), este último introduzido por Rockafellar e Uryasev (2000), e são empregadas amplamente no mercado financeiro e na otimização de portfólios. O VaR é o quantil (percentil inferior) de uma distribuição de perdas, para um determinado nível de confiança  $\alpha$ , já o CVaR é a média das perdas que excedem o VaR dado um nível de confiança (SARYKALIN et al., 2008).

Nessa pesquisa, será considerado  $\alpha \in (0,1)$  como nível de confiança de VaR/CVaR, e  $\zeta$  para o ponto de corte (quantil) associado ao VaR no nível  $\alpha$ , a partir de onde calcula-se o CVaR. Nesse estudo, a perda que será avaliada será o déficit de capacitação em um curso  $m$ , de um navio  $n$ , no mês  $t$ , sob um cenário possível  $\omega$ , representado por  $D_{n,m,t,w}$ , definido como a diferença entre o índice mínimo e o índice observado nesse cenário:

$$D_{n,m,t,w} = Ind_{n,m}^{min} - Ind_{n,m,t,w} \quad (5)$$

Em que  $Ind_{n,m,t,w}$  representa o índice de cursados observado ou projetado para o curso  $m$ , no navio  $n$ , no mês  $t$ , sob um cenário  $\omega$ . Valores positivos de  $D_{n,m,t,w}$  indicam déficit (índice abaixo do mínimo) e valores negativos indicam que o índice atingiu ou superou o mínimo.

Linsmeier e Pearson (1996) apresentam o Value-at-Risk (VaR), uma medida estatística que estima a perda máxima em uma carteira, considerando condições normais de mercado, em um horizonte de tempo específico e com certo nível de confiança. Isso surgiu para atender a necessidade de gestores de terem um número de referência para supervisionar o risco de carteiras compostas por diversos ativos. Uma das formas de se obter o VaR é através de simulação histórica, onde são usadas mudanças reais nos fatores do mercado dos períodos passados, para simular possíveis perdas da carteira mantida no presente. Outra forma apresentada pelos autores é através da simulação de Monte Carlo, onde são gerados vários cenários simulados de variações dos fatores de risco, de acordo com uma distribuição estatística assumida, de forma a estimar possíveis variações de valor da carteira.

O VaR no nível de confiança  $\alpha$  é o quantil  $\alpha$  da distribuição de perdas por cenário, considerado o menor valor que não é excedido em  $\alpha \cdot 100\%$  dos cenários e, portanto, separa a cauda de probabilidade  $1 - \alpha$  das perdas. Ela é uma medida utilizada como um ponto de corte de risco (ROCKAFELLAR e URYASEV, 2000; SARYKALIN et al., 2008). Seja  $L$  uma variável aleatória de perda com distribuição  $F_L$ , o VaR com nível de confiança  $\alpha \in (0, 1)$  é definido como:

$$VaR_{\alpha}(L) = \inf\{\ell \in \mathbb{R} : F_L(\ell) \geq \alpha\} \quad (6)$$

O menor valor de  $\ell$  tal que, em aproximadamente  $\alpha \cdot 100\%$  dos cenários, a perda não observada não excede  $\ell$ , restando uma probabilidade de cerca de  $1 - \alpha$  da perda ser maior que esse patamar. Por exemplo, se  $\alpha = 0.80$  (80% de confiança), o  $VaR_{0.80}(L)$  é o valor da perda que não será excedido em 80% dos cenários. O equivalente é dizer que há 20% de probabilidade de a perda ser maior que o VaR.

O VaR é amplamente usado, porém apresenta algumas limitações (ARTZNER et al., 1999; ROCKAFELLAR e URYASEV, 2000):

- a) Não captura a magnitude das perdas extremas, pois informa somente o ponto de corte, não dizendo o quão graves são as perdas ao passar desse valor;
- b) Não satisfaz a propriedade de subaditividade, pois ao combinar dois portfólios, o VaR do portfólio agregado pode resultar em um risco maior do que considerar a soma dos VaRs individuais, contrariando a intuição de que a diversificação deveria reduzir o risco;
- c) Não é uma medida convexa, dificultando a garantia de soluções ótimas globais em problemas de otimização.

O CVaR, também chamado *Expected Shortfall* (ES), é a média das perdas que ficam além do VaR dado um nível  $\alpha$ :

$$CVaR_{\alpha}(L) = \frac{1}{1 - \alpha} \int_{\ell \geq VaR_{\alpha}(L)} \ell dF_L(\ell) \quad (7)$$

Na equação acima,  $F_L$  é a função distribuição de  $L$ . Assim, o CVaR é a média das perdas que excedem o VaR no mesmo nível  $\alpha$ , o que o torna coerente e convexo, adequado à otimização (ARTZNER et al., 1999; ACERBI; TASCHE, 2002; ROCKAFELLAR; URYASEV, 2000).

O CVaR possui as seguintes propriedades superiores ao VaR (ACERBI e TASCHE, 2002; ARTZNER et al., 1999; ROCKAFELLAR e URYASEV, 2000):

- a) É subaditivo, monotônico, possui homogeneidade positiva e invariância translacional;
- b) É uma medida convexa de risco, facilitando a resolução de problemas de otimização;
- c) É sensível a cauda de distribuição, capturando a magnitude das perdas extremas e não apenas a sua probabilidade ocorrência;

- d) Em geral, minimizar o CVaR em um dado nível de confiança contribui para reduzir também o VaR correspondente, apesar do contrário não ser garantido.

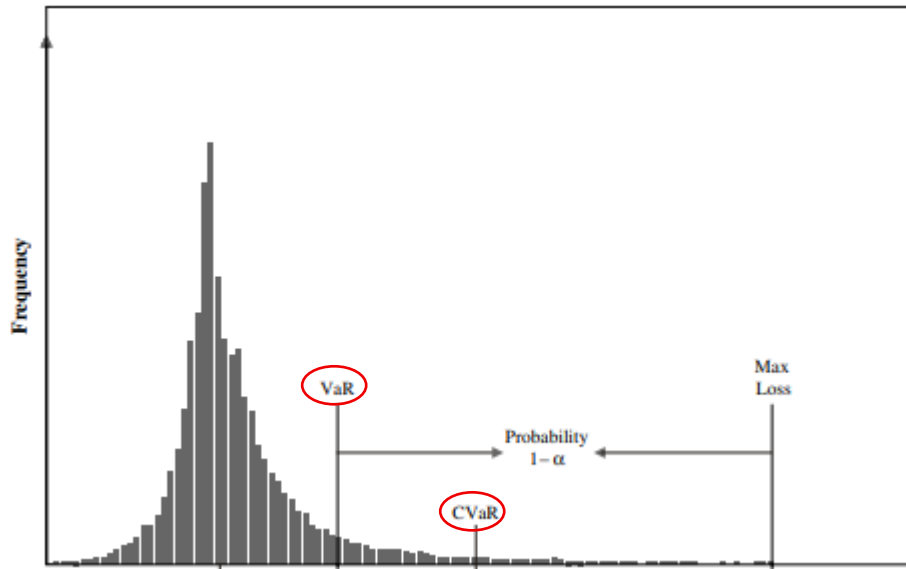


Figura 7 – Figura ilustrativa de VaR e CVaR. Fonte: Adaptado de Sarykalin et al. (2008).

Para exemplificar numericamente os conceitos de VaR e CVaR, suponha 10 cenários de déficit em cursos (em vagas):  $[0,0,1,1,2,3,3,4,6,8]$ , o VaR 80% ( $\alpha = 0,80$ ) é o 80º percentil que é igual a 4, ou seja, em 8 de 10 cenários a perda é menor ou igual a 4. O CVaR 80% representa a média dos 20% piores cenários, média de  $[6, 8] = 7$ . Garantir  $\text{VaR} = 4$  limita o ponto de corte, garantir  $\text{CVaR} = 7$  controla a gravidade média nos piores casos.

Sarykalin et al. (2008) fizeram um estudo comparativo entre VaR e CVaR. Os autores afirmam que o CVaR é uma medida de risco coerente e convexa, facilitando a otimização de restrições, já o VaR pode ser não convexo e não coerente (especialmente com distribuições discretas), dificultando a otimização. Do ponto de vista estatístico, destacam que estimativas de VaR tendem a ser mais estáveis do que as de CVaR quando as caudas não são bem modeladas, porém alertam que comparar ambos no mesmo nível de confiança  $\alpha$  pode ser enganoso, pois “olham” fatias diferentes da cauda. Foi concluído que o ideal é escolher a medida conforme o objetivo e a qualidade do modelo de cauda: indicando o CVaR quando é crítico controlar extremos, ou o VaR quando a modelagem de caudas é fraca ou quando simplicidade/regulação pesam, apesar dele não controlar o que acontece além do quantil.

Zhu et al. (2020) observaram o desafio de quantificar o risco em simulação estocástica quando os parâmetros de entrada são incertos devido à estimação a partir de dados finitos, focando na inferência sobre cenários extremos da resposta média. Para lidar com a incerteza de entrada, os autores empregaram uma abordagem de simulação Monte Carlo aninhada (*nested Monte Carlo*), onde uma camada externa amostra possíveis valores dos parâmetros de entrada a partir dos dados observados, e para conjunto de parâmetros, uma camada interna realiza múltiplas replicações que estimam o valor médio da resposta. A partir da distribuição dessas respostas médias calcularam VaR e CVaR. Em experimentos variando o tamanho da amostra utilizado para estimar os parâmetros de entrada, foi observado que amostras menores ampliam a incerteza e tendem a produzir estimativas mais dispersas, alargando os intervalos de confiança para essas mediadas de risco, ao passo que amostras maiores estabilizam as estimativas. Na atual pesquisa, as medidas de VaR e CVaR obtidas a partir de simulações são interpretadas como indicadores aproximados para comparação entre alternativas de alocação de vagas, e não como representações exatas do risco verdadeiro.

Resumindo, o VaR é bom para fornecer um limite para as perdas em um determinado nível de confiança, porém não apresenta a magnitude do que acontece além desse ponto. O CVaR, por outro lado, é útil para informar a gravidade dos cenários além do limite estipulado pelo VaR, considerando a média dos piores cenários. Essas medidas de risco podem ser complementadas pelo julgamento de um especialista da área.

## 2.5 OPINIÃO DE ESPECIALISTA

O uso da opinião de especialista é importante em contextos em que há elevada complexidade e incerteza, como em casos de distribuição otimizada de recursos, além da previsão de necessidades. A inclusão dessa abordagem, contribui para decisões mais embasadas e seguras, podendo complementar os resultados provenientes de modelos matemáticos e realizando um processo de distribuição mais eficiente e adaptado à realidade operacional da Marinha.

Szwed (2016) apresenta a opinião de especialista como uma fonte extremamente importante que fornece uma contribuição vital aos gerentes de projeto, de forma a garantir que os projetos sejam concluídos com sucesso, no prazo e dentro do orçamento, de acordo com as expectativas das partes interessadas. O autor afirma que essa prática permite lidar com as incertezas e fatores desconhecidos no gerenciamento da natureza temporária e específica de cada projeto. As informações provenientes do especialista visam preencher

as lacunas referentes a ausência de dados históricos ou informações importantes, que são necessárias para estimar recursos necessários, prever cenários futuros ou possíveis riscos.

Petropoulos et al. (2018) evidenciam que a seleção de modelos de previsão não deve se restringir apenas a abordagens estatísticas, os autores demonstram que o julgamento humano, quando aplicado tanto na escolha direta de modelos quanto na identificação de características estruturais das séries temporais, apresenta desempenho comparável ou superior ao dos algoritmos, especialmente na capacidade de evitar os piores modelos. A pesquisa mostra que a combinação entre julgamentos humanos e métodos estatísticos pode gerar ganhos adicionais de precisão e reforçam a robustez das decisões. Os resultados destacaram a importância de considerar a integração entre métodos quantitativos e julgamento humano como estratégia para aprimorar a confiabilidade das previsões em contextos de incerteza.

Zellner et al. (2021), revisam de forma abrangente o uso de julgamento humano, métodos quantitativos e abordagens híbridas de previsão. Os autores argumentam que nem o julgamento de especialistas nem os modelos estatísticos são universalmente superiores, afirmam que o desempenho relativo de cada um depende da quantidade e qualidade dos dados disponíveis, do horizonte temporal, do contexto decisório e do tipo de informação relevante. Por essa razão, os autores recomendam esquemas estruturados de combinação entre previsões algorítmicas e conhecimento especializado, seja pela seleção de modelos, pela realização de ajustes de julgamento às previsões ou por procedimentos formais de combinação de múltiplas fontes de previsão, destacando a importância de desenhar processos de previsão em que métodos estatísticos e julgamento de especialistas interajam de forma complementar.

Petropoulos et al. (2022) afirmam que o julgamento humano possui uma importância crítica no contexto de previsão, pois são realizadas em contextos sociais e inevitavelmente são influenciadas por políticas organizacionais e agendas pessoais. A sua relevância está na integração de informações contextuais e externas, não capturadas por modelos estatísticos baseados em dados históricos, que às vezes são escassos ou inexistentes, ou quando apresentam erros de registros. Nesses casos, os autores alegam que a opinião do especialista acaba sendo a opção mais relevante em situações de alta incerteza em previsões, sendo comumente aplicada na prática por meio de ajustes em previsões geradas por computadores ou na seleção do modelo estatístico mais apropriado.

Senna et al. (2022) evidenciam que a inclusão de variáveis qualitativas em modelos preditivos quantitativos, como as séries temporais, mostrou um aumento na

qualidade das previsões geradas, melhorando modelos considerados precisos. Os estudos realizados pelos autores mostraram que a união dessas variáveis é realizada transformando as características qualitativas em entradas quantificadas, com valores numéricos que podem ser definidos por especialista. Essa revisão sistemática mostrou que houve melhoria dos modelos criados com essa integração, podendo melhorar a qualidade de outras variáveis do sistema, evidenciando o potencial de desenvolvimento de modelos mais precisos com a inclusão de fatores qualitativos.

Pino et al. (2023) falam sobre função estratégica do especialista na validação de instrumentos de coleta de informações para fins comerciais e a sua importância. É apresentado e contextualizado o papel do especialista, com o perfil adequado, na avaliação da qualidade dos dados e na confiança das inferências de uma pesquisa. Como benefícios, a opinião dos especialistas permitiu uma avaliação criteriosa dos itens que compõem o instrumento, ajudando a eliminar os que são irrelevantes, corrigindo as falhas e fortalecendo os seus aspectos importantes, contribuindo com o aumento da qualidade das decisões que serão tomadas a partir das informações coletadas.

Os trabalhos apresentados mostram que a opinião de um especialista na área poderá contribuir para o aperfeiçoamento da técnica de otimização que será desenvolvida, do ponto de vista a incluir percepções, baseadas em experiência, que complementarão os resultados gerados pelos modelos tanto de distribuição como de previsão.



### 3 METODOLOGIA

#### 3.1 CLASSIFICAÇÃO DA PESQUISA

O presente trabalho é caracterizado como uma pesquisa aplicada, pois busca solucionar um problema real da MB, no que tange a otimização da distribuição de vagas em cursos para o pessoal que serve embarcado. Segundo Gil (2017), esse tipo de pesquisa busca gerar conhecimentos para aplicação prática, sendo direcionados a problemas específicos.

No quesito abordagem, é classificada como pesquisa quali-quantitativa, devido a necessidade de modelagem matemática para a resolução do problema, e pela incorporação da opinião de especialista para complementar a parte quantitativa. Gerhardt e Silveira (2009) dizem que a pesquisa qualitativa visa o aprofundamento da compreensão do fenômeno estudado, enquanto a pesquisa quantitativa visa a objetividade e mensuração dos dados, a junção das duas permite uma análise mais completa do problema estudado.

Quanto aos fins e objetivos, é classificada como descritiva-explicativa. Descritiva pois descreve os atuais processos de distribuição de vagas em cursos, com a identificação de padrões e tendências existentes. Explicativa pois busca identificar os fatores que contribuem para a otimização do processo, além de estabelecer relações de causa e efeito entre as variáveis estudadas. Gil (2017) diz que a pesquisa descritiva descreve as características de determinadas populações ou fenômenos, e a pesquisa explicativa identifica os fatores que determinam ou contribuem para os acontecimentos estudados.

No que tange ao procedimento técnico, a pesquisa é classificada como um estudo de caso, pois é referente a uma situação específica da MB, em que é possível estudar um fenômeno em seu contexto real. Yin (2015) afirma que o estudo de caso é uma estratégia de pesquisa abrangente, onde é investigado um fenômeno dentro de seu contexto da vida real.

#### 3.2 COLETA DOS DADOS

Os dados foram coletados junto aos navios/Esquadrão, e todos se encontravam em formato de planilha eletrônica. O controle de cursados era enviado mensalmente do navio para o Esquadrão, que os compilava. Para facilitar a análise foram compilados todos os dados do período de 2020 a 2023 dos cursos dos três navios em uma única planilha. Os

dados coletados se trata de uma amostra, pois na realidade há mais cursos que são feitos pelos navios, e há mais navios no Esquadrão.

Devido as restrições dos dados, os cursos considerados nessa pesquisa foram identificados por números, e os custos foram normalizados pela soma total e posteriormente multiplicados por um valor de referência, de modo a preservar as proporções originais entre eles. Os custos foram levantados para acrescentar mais uma análise, pois o Esquadrão não é o responsável pelos pagamentos dos cursos, e sim outra Organização Militar superior, que não foi abordada neste estudo. As vagas que foram efetivamente distribuídas em 2023, juntamente com os custos normalizados, encontram-se na tabela abaixo:

Tabela 2 – Vagas distribuídas em 2023 e custo por aluno

	Vagas disponíveis em 2023	Custo individual por aluno
Curso 1	2	R\$ 7.094,75
Curso 2	3	R\$ 5.170,53
Curso 3	4	R\$ 163,57
Curso 4	113	R\$ 91,41
Curso 5	0	R\$ 700,92
Curso 6	32	R\$ 94,71
Curso 7	3	R\$ 360,47
Curso 8	3	R\$ 1.010,14
Curso 9	2	R\$ 658,87
Curso 10	13	R\$ 305,08
Curso 11	8	R\$ 190,89
Curso 12	23	R\$ 1.227,28
Curso 13	39	R\$ 96,23
Curso 14	2	R\$ 319,08
Curso 15	26	R\$ 232,34
Curso 16	4	R\$ 713,34
Curso 17	27	R\$ 130,63
Curso 18	23	R\$ 1.439,76

### 3.3 ANÁLISE EXPLORATÓRIA DOS DADOS

A partir dos dados coletados foi realizada uma análise exploratória inicial, por meio de análise gráfica, verificação de estacionariedade, dependência temporal, indicadores de dispersão e presença de zeros excessivos. O intuito foi de identificar padrões de comportamento e restrições impostas pelos dados, de forma a obter indícios modelo de séries de contagem que seria mais bem aplicado para representar o

comportamento deles. Inicialmente, verificou-se algumas estatísticas descritivas dos dados das séries dos cursos, para os navios 1, 2 e 3:

Tabela 3 – Estatísticas descritivas dos cursos do navio 1

curso	min	max	media	mediana	IQR
Curso 1	1	3	1,85	2,00	1,00
Curso 2	3	4	3,40	3,00	1,00
Curso 3	2	15	8,35	10,00	8,25
Curso 4	84	189	103,00	97,50	15,25
Curso 5	0	3	1,50	1,50	1,00
Curso 6	27	50	37,00	39,00	11,50
Curso 7	10	18	12,96	13,00	1,25
Curso 8	0	4	1,67	1,00	2,00
Curso 9	3	14	8,79	9,00	4,00
Curso 10	6	10	8,21	8,00	2,00
Curso 11	6	13	9,67	9,50	4,00
Curso 12	5	12	6,73	6,00	1,25
Curso 13	12	23	17,75	18,00	2,00
Curso 14	1	3	1,90	2,00	2,00
Curso 15	10	21	13,52	13,00	4,00
Curso 16	1	6	2,63	2,00	2,00
Curso 17	9	24	17,17	18,50	5,00
Curso 18	9	23	15,17	14,00	4,00

Tabela 4 – Estatísticas descritivas dos cursos do navio 2

curso	min	max	media	mediana	IQR
Curso 1	0	2	1,13	1,00	0,00
Curso 2	1	3	1,71	2,00	1,00
Curso 3	3	7	5,83	6,00	1,50
Curso 4	127	248	173,21	177,00	32,25
Curso 5	0	3	2,23	3,00	2,00
Curso 6	31	77	51,31	51,00	18,25
Curso 7	5	21	12,67	14,00	7,00
Curso 8	1	6	3,29	3,00	2,00
Curso 9	2	10	6,23	6,00	5,25
Curso 10	2	8	4,48	4,00	1,25
Curso 11	7	19	11,83	11,00	5,00
Curso 12	1	12	6,58	6,00	7,25
Curso 13	18	37	27,63	30,50	14,00
Curso 14	1	7	3,27	2,00	4,00
Curso 15	17	32	24,33	24,00	9,50
Curso 16	2	13	7,08	9,00	9,00
Curso 17	14	33	22,25	23,50	12,25
Curso 18	13	31	22,08	22,00	12,25

Tabela 5 – Estatísticas descritivas dos cursos do navio 3

curso	min	max	media	mediana	IQR
Curso 1	4	8	5,67	5,00	3,00
Curso 2	1	6	4,38	4,50	2,25
Curso 3	9	13	12,00	13,00	2,00
Curso 4	169	280	219,83	223,50	60,75
Curso 5	4	10	7,71	8,50	3,00
Curso 6	57	84	66,29	66,00	8,00
Curso 7	18	22	19,96	20,00	0,25
Curso 8	0	6	2,63	2,00	2,00
Curso 9	1	3	2,60	3,00	1,00
Curso 10	4	11	6,27	6,00	2,00
Curso 11	10	22	16,73	18,00	10,00
Curso 12	7	14	10,15	9,00	4,00
Curso 13	26	91	57,29	69,50	47,00
Curso 14	4	7	5,19	5,00	0,00
Curso 15	21	33	27,33	28,50	6,25
Curso 16	11	13	12,00	12,00	2,00
Curso 17	9	47	24,90	25,50	5,25
Curso 18	10	39	18,50	16,00	6,00

Na análise gráfica, são apresentadas a série histórica da quantidade de cursados, por curso e navio, com a média e índices ideal/mínimo, juntamente com histograma e a estimativa de densidade por kernel (*Kernel Density Estimate* – KDE), além do boxplot. Inicialmente, é apresentado o gráfico do curso 12, citado na introdução, demais cursos encontram-se no apêndice A.

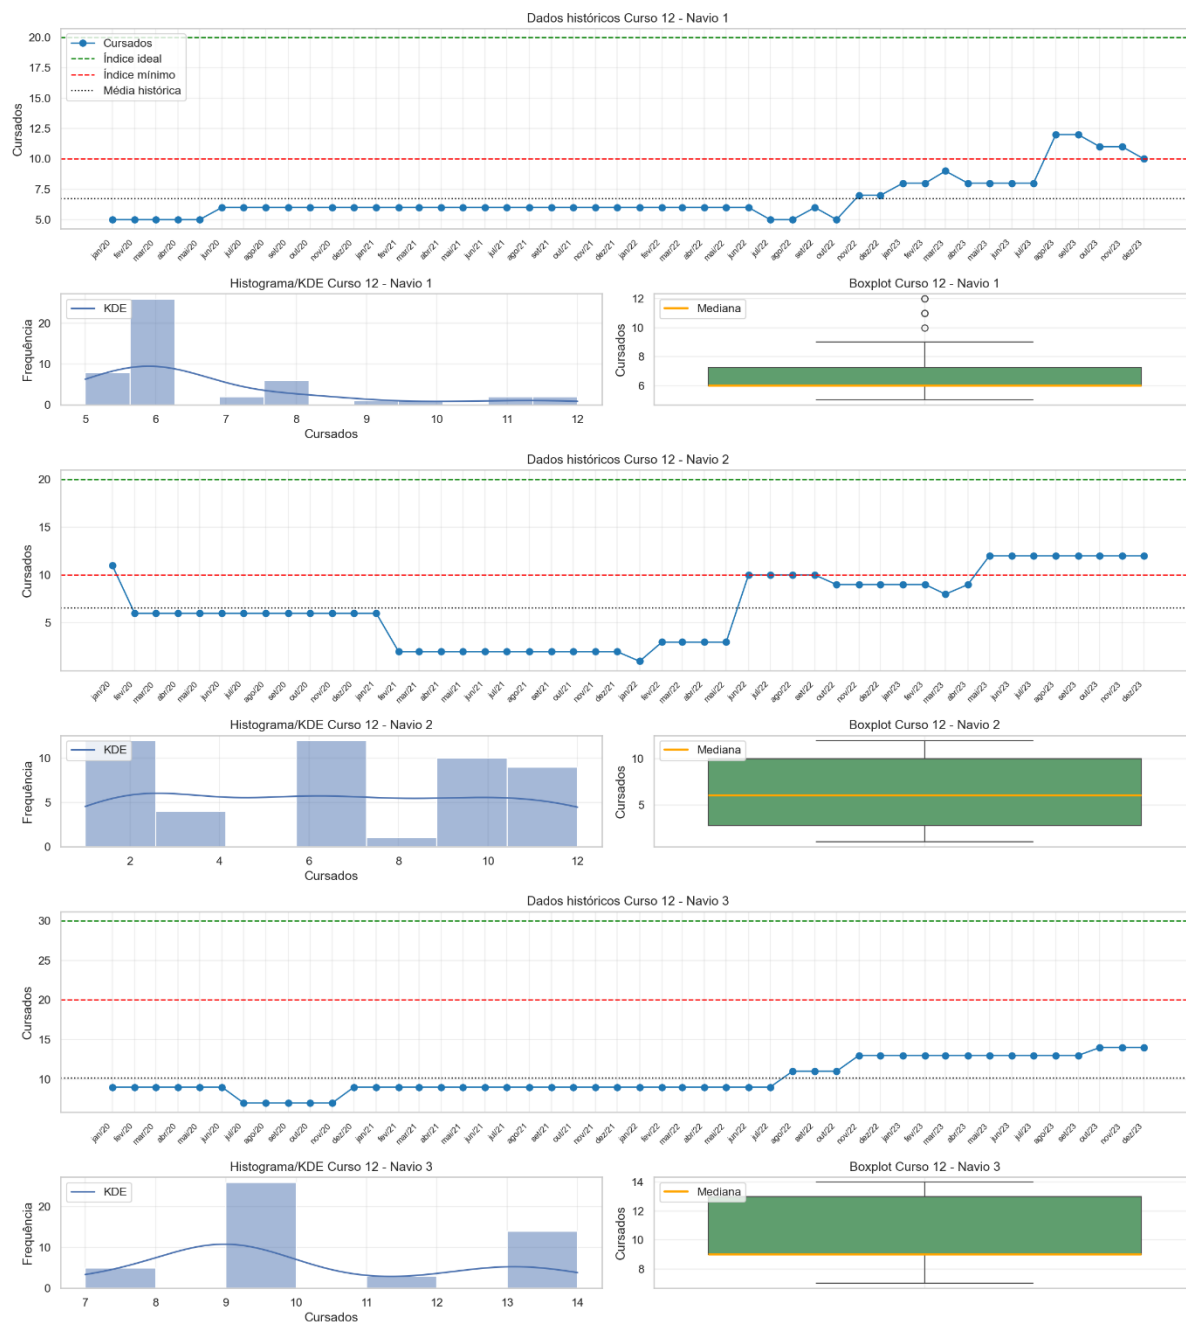


Figura 8 – Análise exploratória Curso 12

Após a visualização inicial, é importante a execução de testes de raiz unitária e estacionariedade, neles o “span” temporal (duração no tempo) é determinante para o poder e para o tamanho do teste, os aumentos na frequência de amostragem (com período fixo) tendem a produzir ganhos marginais decrescentes (PERRON, 1989). Para verificar a estacionariedade das séries dos cursos através de testes formais, foram aplicados dois testes de forma complementar:

1. Augmented Dickey–Fuller (ADF), onde a hipótese nula é a presença de raiz unitária (não-estacionariedade);
2. Kwiatkowski–Phillips–Schmidt–Shin (KPSS), onde hipótese nula é de estacionariedade (em nível ou em tendência, conforme a especificação).

Levando em consideração que os testes possuem hipóteses nulas opostas, e apresentam sensibilidades distintas em amostras finitas, foi adotado o seguinte critério de classificação: *“Uma série é considerada estacionária somente quando houver concordância entre os testes, isto é, ao mesmo nível de significância de 5% o ADF rejeita a hipótese nula de raiz unitária e o KPSS **NÃO** rejeita a hipótese nula de estacionariedade”*. Em outras palavras, será considerado estacionariedade somente quando para ADF o p-valor  $< 0.05$  e para KPSS o p-valor  $> 0.05$ . A adoção do critério de dupla concordância visou tentar reduzir a probabilidade de classificações equivocadas em amostras curtas, pois nesses casos a confiabilidade do poder do teste é reduzida, especialmente na presença de erros auto correlacionados (KWIATKOWSKI et al., 1992).

Ambos os testes foram aplicados considerando que os dados possuíam ou não tendência, no caso de ocorrer eventuais tendências fracas por causa do tamanho da amostra, os resultados dos testes em todas as séries encontram-se no apêndice B. Após aplicação dos testes nas duas possibilidades, apenas 5 séries das 54 apresentaram comportamento estacionário segundo o critério adotado, a grande maioria apresentou comportamento não estacionário, que foi de aproximadamente 91%. Apesar dessa quantidade de dados permitir uma caracterização preliminar dos processos dos cursos, é importante reconhecer que amostras dessa magnitude implicam em limitações ao poder estatístico de testes formais e à capacidade de identificação de padrões complexos em séries temporais, como tendências fracas ou sazonalidade incipiente (HYNDMAN; ATHANASOPOULOS, 2021; PETROPOULOS et al., 2022; HOPKIN et al., 2015; PERRON, 1989).

A visualização gráfica indica forte associação entre valores consecutivos e mudanças pouco frequentes, com trechos longos em patamares (platôs) e transições por degraus de nível. Essas mudanças estruturais observadas nas séries podem ser interpretadas como um choque integrador duradouro, que altera a trajetória esperada delas, e a acumulação dessas mudanças estruturais ao longo do tempo produz a evolução não estacionária observada, podendo estar atrelado à possibilidade de mudanças operacionais ou institucionais na Marinha do Brasil.

Isso sugere dependência de curto prazo relevante e propagação do nível entre períodos, quadro compatível com processos em que o estado (nível) persiste e é perturbado por inovações discretas, condizendo com um comportamento de processos estocásticos que incorporam inovações de forma cumulativa (ENDERS, 2015). Em amostras curtas, a avaliação gráfica ajuda a contextualizar a inferência formal, pois cada observação tem peso desproporcional na estimação (HYNDMAN e ATHANASOPOULOS, 2021; PETROPOULOS et al., 2022).

Ao observar os gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF), é possível verificar se há indícios de tendência estocástica (raiz unitária) quando são observados os seguintes pontos recorrentes (HASSANI et al., 2024; HYNDMAN e ATHANASOPOULOS, 2021):

- a) a ACF dos níveis permanece alta e positiva por muitas defasagens, decaindo lentamente (não “corta” logo para zero);
- b) a PACF exibe um pico dominante no *lag* 1 e ausência de picos relevantes nos *lags* seguintes.

Para esta análise, foram gerados gráficos ACF e PACF para 12 *lags* nas séries dos cursos, devido aos dados serem mensais. Por exemplo, são apresentados novamente os gráficos do curso 12 da comentado na introdução, demais encontram-se no apêndice C.

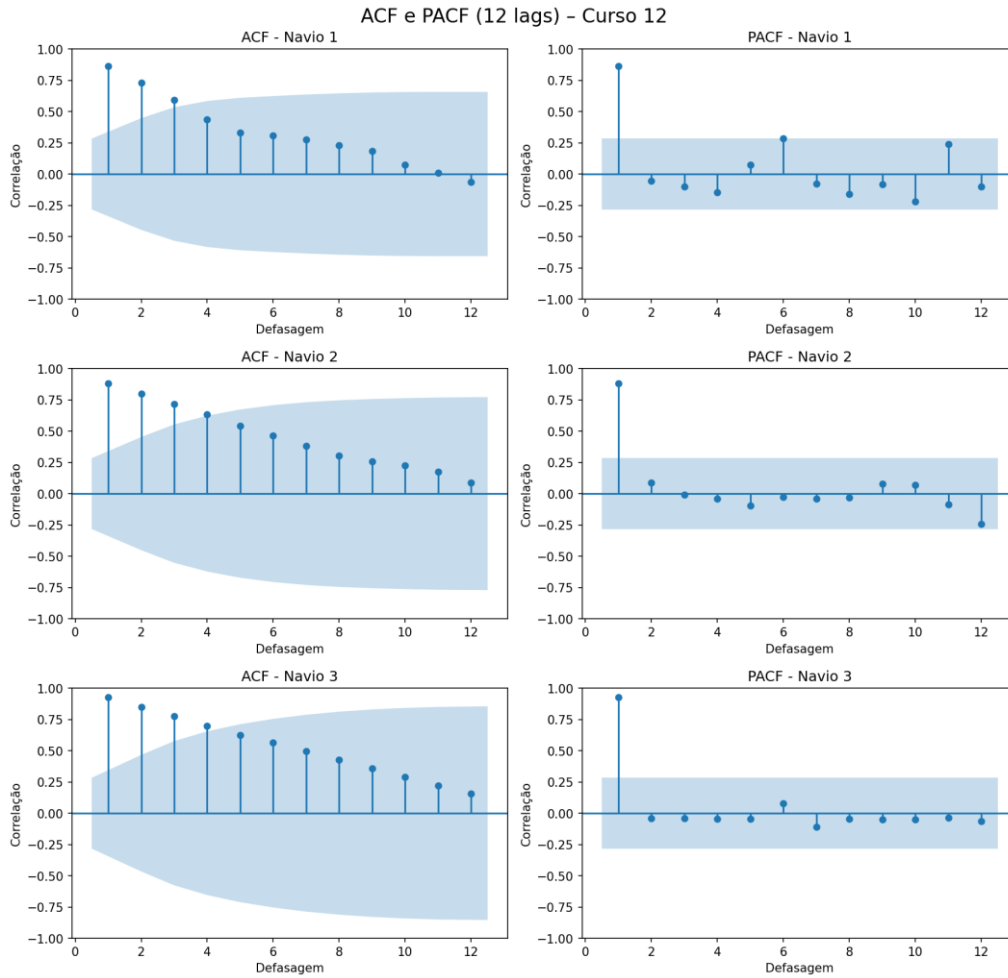


Figura 9 – Gráficos de ACF/PACF para o Curso 12

Os gráficos apresentaram persistências marcantes sem sinais claros de sazonalidade, que seriam picos consistentes no *lag* 12. Na maioria das séries a ACF dos níveis permaneceu elevada e decaiu lentamente, com valores positivos e decaimento lento ao longo das defasagens. Para o PACF, observou-se, majoritariamente, pico pronunciado no *lag* 1, e ausência de pico nos *lags* seguintes. Para amostras curtas, é recomendado concentrar a interpretação nos *lags* baixos ( $\sqrt{n} = \sqrt{48} \cong 7$ , onde  $n$  é o tamanho da série), onde as bandas de confiança são mais estáveis, garantindo maior confiabilidade estatística das estimativas (HASSANI et al., 2024; HYNDMAN e ATHANASOPOULOS, 2021).

O índice de dispersão foi calculado para todos os cursos, de forma a identificar casos de equi-, sobre- ou subdispersão, além do percentual de zeros. Como se trata de uma amostra, foram utilizados estimadores amostrais, que para o índice de dispersão é:

$$\hat{I} = \frac{S^2}{\bar{X}} \quad (8)$$



Onde:

- $\hat{I}$  é o estimador amostral do índice de dispersão;
- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  é a variância amostral não viesada;
- $\bar{X} = \frac{1}{n-1} \sum_{i=1}^n X_i$  é a média amostral;
- $n$  é o tamanho da amostra.

Nos casos em que:

- $\hat{I} \approx 1$ : há equidispersão;
- $\hat{I} > 1$ : há sobredispersão;
- $\hat{I} < 1$ : há subdispersão.

O percentual de zeros amostrais observados é calculado como:

$$\widehat{P}_0 = \frac{n_0}{n} \quad (9)$$

Onde:

- $\widehat{P}_0$  é o estimador amostral da proporção de zeros;
- $n_0$  é o número de observações iguais a zero na amostra;
- $n$  é o tamanho da amostra.

Após os cálculos dos índices e das proporções de zero da amostra em todos os cursos e navios, os dados foram tabelados, sendo indicado com \* os cursos subdispersos e com \*\* os sobredispersos:

Tabela 6 – Índices de dispersão e proporção de zeros

Curso	$\hat{I}_1$	$\hat{I}_2$	$\hat{I}_3$	$\widehat{P}_{0,1}$	$\widehat{P}_{0,2}$	$\widehat{P}_{0,3}$
<b>Curso 1</b>	0,30*	0,14*	0,39*	0	0,02	0
<b>Curso 2</b>	0,07*	0,32*	0,64*	0	0	0
<b>Curso 3</b>	2,36**	0,36*	0,16*	0	0	0
<b>Curso 4</b>	2,62**	4,11**	4,56**	0	0	0
<b>Curso 5</b>	0,34*	0,42*	0,45*	0,06	0,02	0
<b>Curso 6</b>	1,25**	3,81**	0,94*	0	0	0
<b>Curso 7</b>	0,23*	2,21**	0,05*	0	0	0
<b>Curso 8</b>	1,13**	0,72*	1,40**	0,21	0	0,19
<b>Curso 9</b>	0,75*	0,97*	0,18*	0	0	0
<b>Curso 10</b>	0,16*	0,66*	0,44*	0	0	0
<b>Curso 11</b>	0,64*	0,67*	1,45**	0	0	0
<b>Curso 12</b>	0,49*	2,12**	0,46*	0	0	0

<b>Curso 13</b>	0,39*	1,63**	8,44**	0	0	0
<b>Curso 14</b>	0,36*	1,65**	0,13*	0	0	0
<b>Curso 15</b>	0,72*	1,05**	0,64*	0	0	0
<b>Curso 16</b>	0,71*	3,08**	0,06*	0	0	0
<b>Curso 17</b>	0,91*	1,79**	4,10**	0	0	0
<b>Curso 18</b>	1,08**	1,84**	3,87**	0	0	0

Os cálculos reportaram 33 séries com índice de dispersão menor que 1, e 21 séries com índice de dispersão superior a 1. Em relação à proporção de zeros, somente dois casos chamaram atenção que foram referentes ao curso 8 dos navios 1 e 3, com proporções de zeros 0,21 e 0,19, respectivamente. A combinação de séries com subdispersão e sobredispersão, bem como a presença moderada de zeros em grande parte das séries, indica que nenhuma distribuição única descreve perfeitamente todos os cursos.

Após essas verificações iniciais nos dados, foi realizada uma entrevista com o especialista do Esquadrão responsável pela distribuição das vagas para os navios, pois devido ao tamanho curto da amostra, observou-se a necessidade de acrescentar ao processo de inferência estatística um julgamento especializado, de forma a complementar a análise quantitativa com conhecimentos inerentes da área (HYNDMAN e KOSTENKO, 2007).

### 3.4 COLETA DA OPINIÃO DO ESPECIALISTA

Para complementar a análise quantitativa, foi incorporado a opinião de um especialista responsável pela alocação de vagas, que trabalhou cerca de cinco anos nessa função. O fato de a entrevista ter ocorrido somente com um especialista, foi devido ao fato da hierarquia no processo permitir somente um decisor no Esquadrão. Através de uma entrevista ele informou que a quantidade de cursados pode variar com embarques/desembarques de pessoal, devido a questões como:

- a) O militar veio de um centro de formação e não possui cursos, ou veio de outra OM que não possui os cursos exigidos por aquele navio;
- b) O militar veio de outra OM e já possui alguns cursos exigidos por aquele navio;
- c) O militar ser selecionado em um processo seletivo para servir em outra OM, e desembarca em atendimento ao interesse da administração naval superior ao navio/Esquadrão;

- d) O militar ser selecionado em um processo seletivo ao qual ele tenha sido voluntário para servir em outra OM ou para participar de uma missão específica, e isso gera o seu desembarque;
- e) Solicitação de movimentação do militar para outra OM, que pode ser atendida em um momento não esperado;
- f) Questões de saúde do militar que restrinjam o seu embarque;
- g) Questões familiares em que o militar pede uma licença que às vezes culmina no seu desembarque.

Esses pontos indicam que a quantidade de militares cursados a bordo varia em função de eventos discretos de ingresso e saída de pessoal, muitos deles difíceis de antecipar com precisão. Do ponto de vista da modelagem, essas ocorrências podem ser interpretadas como choques aleatórios que podem produzir incrementos, como aumentos ou redução, na contagem de cursados ao longo do tempo.

Além disso, foi informado pelo entrevistado que o ano de 2020 foi atípico devido a pandemia de COVID-19, onde os cursos não foram oferecidos da mesma forma que em anos anteriores pois eram presenciais. Nessa época, a MB precisou se reorganizar para adaptar-se as novas restrições impostas, e essa situação foi se normalizando em 2021. Isso pode ser observado nos gráficos em 2020, pois a quantidade de cursados tinha pouca variação ou queda.

Há situações em que uma vaga de um curso pode ser transferida de um navio para outro, mesmo após a distribuição anual de vagas, que geralmente ocorre no mês de abril. Isso geralmente ocorre pela indisponibilidade do militar que faria o curso, pois os cursos são ministrados em diferentes épocas do ano, e pode acontecer o caso de em determinado período em que o curso seria ministrado, o navio ter saído para cumprir determinada missão, então o militar que faria esse curso estaria fora, e para não perder essa vaga, ela é realocada para outro navio.

Outra situação, menos frequente, que às vezes pode resultar em transferência de vagas em curso, é o navio ter recebido uma vaga para determinado curso, e ocorrer o embarque de militares que já possuem aquela qualificação, logo o índice para aquele curso aumentaria e a administração do navio entende que não seria necessário mais enviar um militar cursar.

Mais uma possibilidade é quando um Esquadrão recebe vaga de outro, devido aos eventos já apresentados, como indisponibilidade de pessoal ou aumento não esperado dos

índices devido a embarque de pessoal. Isso resulta novamente em realocação ao longo do ano, de vagas já tinham sido distribuídas.

Esses acontecimentos são monitorados pelo pessoal responsável pela alocação de vagas no Esquadrão, e o especialista disse que a quantidade de cursados não cresceria indefinidamente, pois devido ao controle mensal que é feito, por mais que haja um aumento na quantidade por um período, são feitos ajustes, quando possível, de forma que o índice ideal seja mantido ou buscado.

Com base na entrevista, foi possível perceber que a quantidade de cursados é resultado de um processo dinâmico, sujeito a choques de entrada e saída de pessoal e a realocações de vagas ao longo do ano, além de ocorrer um acompanhamento mensal que busca manter os valores dos índices próximos dos estabelecidos. Logo, após a características observadas dos dados, tanto na análise exploratória como na entrevista, foi possível elaborar uma sugestão de modelo para gerar possíveis cenários futuros a ser apresentado na próxima seção.

### 3.5 MODELAGEM PARA SIMULAÇÃO

Uma das formas de se realizar uma distribuição otimizada, é através da observação possibilidades futuras, para tentar entender como se comportarão as quantidades de cursados no próximo anos. Durante o processo de análise exploratória dos dados, com a verificação da correlação e estacionariedade das séries, foi observado que havia uma aleatoriedade nos dados que não pode ser explicada observando simplesmente os registros históricos. Houve um entendimento melhor das ocorrências nas séries após a entrevista com o especialista, que clareou a dinâmica do aumento/redução das quantidades de cursados.

Essas realocações dinâmicas constituem decisões sequenciais adaptativas sob incerteza, característica de gestão de recursos em ambientes estocásticos. Corlu et al. (2020) dizem que os processos que possuem ‘incerteza de entrada’, em que decisões futuras dependem de informações incompletas sobre demanda, disponibilidade e eventos aleatórios, requerem modelagem que capture explicitamente a variabilidade empírica ao invés de pressupostos paramétricos rígidos.

Modelar todas essas situações, levando-se em consideração os dados históricos disponíveis (apenas 48 observações), tornaria o modelo extremamente complexo e sujeito a *overfitting*, quando o modelo se ajusta excessivamente aos dados ao invés de capturar o padrão deles (CORLU et al., 2020). Os autores recomendam que nesses casos, a

modelagem deve priorizar parcimônia e incorporar informação externa (como ocorreu com a opinião do especialista) ao invés de tentar extrair estruturas sofisticadas em séries curtas. Logo, optou-se pela elaboração de modelo simples, de forma a se obter uma estimativa razoável do comportamento das quantidades de cursados nos próximos 12 meses.

As simulações estocásticas foram baseadas na formulação de uma série temporal com uma estrutura do tipo *Random Walk*, pois além da amostra restrita dos dados, que compromete a execução de testes estatísticos formais, foram observados os seguintes fatores:

- a) Resultados formais compatíveis com não-estacionariedade, pois em grande parte das séries, ADF não rejeita raiz unitária e KPSS rejeita estacionariedade (critério conjunto).
- b) ACF dos níveis alta e com decaimento lento por vários lags (positiva até lags médios), indicando persistência do nível.
- c) PACF com pico dominante em lag 1 e sem picos relevantes nos demais lags, sugerindo que quase toda a dependência está no primeiro atraso.
- d) Ausência de sazonalidade estável: não há picos consistentes em lag 12 na ACF (dados mensais).
- e) Trajetórias em degraus e platôs nos gráficos de nível: choques alteram o patamar e permanecem por longos períodos (baixa reversão imediata à média).
- f) Bandas de confiança das autocorrelações mais estáveis em lags baixos (amostra curta,  $n = 48$ ), o que favorece modelos parcimoniosos centrados no nível.
- g) Contexto amostral (4 anos): com poucos pontos no tempo, modelos simples tendem a ser mais confiáveis do que especificações complexas, comunicando incerteza e parcimônia.

Diante do exposto, foi elaborada o seguinte modelo em que o valor simulado em um período,  $Y_t$ , foi definido como a soma do valor do período anterior,  $Y_{t-1}$ , com um termo de erro estocástico,  $\epsilon_t$ , conforme formulação abaixo:

$$Y_t = Y_{t-1} + \epsilon_t \quad (10)$$

O termo de erro,  $\epsilon_t$ , foi elaborado de maneira a reproduzir os comportamentos que foram observados de forma empírica nos dados históricos, que foram: (i) a quantidade de cursados permanecia constante de um período para outro ou não, (ii) a quantidade de cursados aumentava ou diminuía e (iii) a quantidade que aumentava ou diminuía de um determinado valor. Devido a essa aleatoriedade dos dados históricos e discretos, optou-se pela utilização de duas distribuições de Bernoulli e uma de Poisson, da seguinte maneira:

$$\epsilon_t = B_t^1 \times (2B_t^2 - 1) \times P_t \quad (11)$$

Onde:

- $B_t^1$  é a primeira variável de Bernoulli, que indica se a quantidade de cursados de um período para o outro alterou ou permaneceu constante; ao ocorrer  $B_t^1 = 1$ , caso contrário  $B_t^1 = 0$ ;
- $B_t^2$  é a segunda variável de Bernoulli, que indica a direção da variação, se a quantidade de cursados de um período para o outro aumentou ou diminuiu, resultando em  $+1$  ou  $-1$ . Se a variação foi positiva considerou-se  $B_t^2 = 1$ , caso contrário  $B_t^2 = 0$ ;
- $P_t$  é a variável de Poisson, que indica a magnitude absoluta da variação, o quanto a quantidade de cursados aumentou ou diminuiu. A taxa neste caso refere-se à variação média de cursados para determinado curso.

Para as simulações geradas por  $Y_t$ , são consideradas somente os casos não negativos, pois não há contabilização de pessoas cursadas que sejam menores que zero, caso isso ocorra na simulação, é atribuído o menor valor.

$$Y_t = \begin{cases} Y_{t-1} + \epsilon_t, & \text{se } Y_{t-1} + \epsilon_t \geq 0 \\ 0, & \text{se } Y_{t-1} + \epsilon_t < 0 \end{cases} \quad (12)$$

A distribuição de Bernoulli é conhecida pela fórmula:

$$P(X = x) = \begin{cases} p, & x = 1 \\ 1 - p, & x = 0 \end{cases} \quad (13)$$

O cálculo da probabilidade de sucesso,  $p_1$ , da primeira distribuição de Bernoulli,  $B_t^1$ , foi a através da contabilização da quantidade de variações ocorridas em instantes consecutivos que fossem diferentes de zero,  $|\Delta_t^1| > 0$ , durante o período dos dados históricos.

$$\Delta_t^1 = y_{t+1} - y_t, \quad \text{para } t = 1, 2, \dots, T - 1 \quad (14)$$

$$p_1 = \frac{\sum_{t=1}^{T-1} I(|\Delta_t^1| > 0)}{T - 1} \quad (15)$$

Para ilustrar esse cálculo, segue o seguinte exemplo de uma série hipotética,  $y_t$ , com 7 termos aleatoriamente escolhidos:

$$y_t = \{1, 2, 3, 3, 5, 4, 7\} \quad (16)$$

$$\Delta_t^1 = \{1, 1, 0, 2, -1, 3\} \quad (17)$$

$$p_1 = \frac{1 + 1 + 1 + 1 + 1}{6} = \frac{5}{6} = 83\% \quad (18)$$

De acordo com a análise dos dados históricos dessa série hipotética, haveria 83% de probabilidade de ocorrer uma mudança de um período para outro.

O cálculo da probabilidade de sucesso,  $p_2$ , da segunda distribuição de Bernoulli,  $B_t^2$ , foi através da contabilização da quantidade de variações positivas ( $\Delta_t^2 > 0$ ) ocorridas em instantes consecutivos, referente aos períodos em que ocorreram variações.

$$\Delta_t^2 = \Delta_t^1, \quad \text{para todo os } t \text{ tal que } \Delta_t^1 \neq 0 \quad (19)$$

$$p_2 = \frac{\sum_{t=1}^{T-1} I(\Delta_t^2 > 0)}{|\Delta_t^2|} \quad (20)$$

Para ilustrar o cálculo da probabilidade empregada na segunda distribuição de Bernoulli, segue o seguinte exemplo utilizando a mesma série hipotética anterior:

$$y_t = \{1, 2, 3, 3, 5, 4, 7\} \quad (21)$$

$$\Delta_t^1 = \{1, 1, 0, 2, -1, 3\} \quad (22)$$

$$\Delta_t^2 = \{1, 1, 2, -1, 3\} \quad (23)$$

$$p_2 = \frac{1 + 1 + 1 + 1}{5} = \frac{4}{5} = 80\% \quad (24)$$

De acordo com o exemplo, haveria 80% de probabilidade de ocorrer uma mudança de um período para outro, cuja variação fosse de aumento.

A magnitude das mudanças foi calculada por uma Poisson, cuja taxa média de variação,  $\lambda$ , verificou a média dos módulos das variações pelo total de variações.

$$P(X = k) = \frac{\lambda^k \times e^{-\lambda}}{k!} \quad (25)$$

$$\lambda = \frac{\sum_{t=1}^{T-1} |\Delta_t^2|}{|\Delta_t^2|} \quad (26)$$

Para ilustrar o cálculo da taxa empregada na distribuição de Poisson, segue o seguinte exemplo utilizando a mesma série hipotética:

$$y_t = \{1, 2, 3, 3, 5, 4, 7\} \quad (27)$$

$$\Delta_t^1 = \{1, 1, 0, 2, -1, 3\} \quad (28)$$

$$\Delta_t^2 = \{1, 1, 2, -1, 3\} \quad (29)$$

$$\lambda = \frac{1 + 1 + 2 + 1 + 3}{5} = \frac{8}{5} = 1,6 \quad (30)$$

Após as simulações, é importante que essas sejam validadas de acordo com alguns critérios, que serão abordados na próxima seção.



### 3.6 VALIDAÇÃO DAS SIMULAÇÕES

Após a especificação do modelo de simulação, foi elaborado um procedimento de validação. Os passos sugeridos por Sargent (2020) foram adaptados, com ênfase na validação de face do modelo, devido às particularidades desse estudo, como: tamanho reduzido da amostra histórica, natureza discreta dos dados e restrições operacionais da política de distribuição de vagas, resultando no seguinte procedimento resumido elaborado em conjunto com o especialista:

- 1- Acordo prévio sobre a abordagem de modelagem adotada, utilizando uma formulação parcimoniosa que melhor representasse os principais mecanismos observados no comportamento dos dados;
- 2- Especificação da faixa de precisão aceitável para as previsões, onde foi definido que elas deveriam manter, aproximadamente, uma trajetória central próxima da média histórica; e
- 3- Validação visual do comportamento das simulações por meio de gráficos do tipo fanchart, avaliando se as séries simuladas são consideradas plausíveis se comparadas ao comportamento real dos dados.

Quando a amostra é pequena, a validação visual gráfica ganha importância, pois testes estatísticos formais tendem a ter baixa potência (HOPKIN et al., 2015; SARGENT, 2020). Como esse tipo de avaliação é considerado subjetivo, é importante que seja conduzido por um especialista na área, de forma a ancorar o julgamento em conhecimento do sistema (HYNDMAN e KOSTENKO, 2007; PETROPOULOS et al., 2022).

Os gráficos do tipo fanchart, ou gráficos em leque, são adequados para a comunicação de previsões probabilísticas, pois permitem visualizar intuitivamente a incerteza dos cenários futuros por meio de faixas graduais de probabilidade. Esse tipo de visualização facilita a compreensão tanto das previsões centrais quanto dos riscos de eventos extremos, auxiliando a tomada de decisão em contextos incertos (GNEITING e KATZFUSS, 2014; SOKOL, 2025).

### 3.7 MODELAGEM DA DISTRIBUIÇÃO DE VAGAS

Com o intuito de verificar a melhor forma de se realizar a distribuição das vagas, foram testados cinco modelos, os dois primeiros sobre a total de vagas a serem

distribuídas em 2023, e os três seguintes sobre as simulações realizadas através da formulação de  $Y_t$ .

### 3.7.1 Modelo 1: PLI

O modelo abaixo foi elaborado para minimizar a diferença absoluta entre o índice resultante após a distribuição anual de vagas (índice atual + vagas recebidas), e o índice ideal para cada curso em cada navio. Ele tenta aproximar o máximo possível os índices atuais do ideal, evitando tanto o excesso como o déficit.

Função Objetivo do Modelo 1:

$$\min \sum_{n \in N} \sum_{m \in M} |Ind_{n,m}^{atual} + V_{n,m} - Ind_{n,m}^{ideal}| \quad (31)$$

Restrições do Modelo 1:

$$Ind_{n,m}^{atual} + V_{n,m} \geq Ind_{n,m}^{min}, \quad \forall n \in N, \forall m \in M \quad (32)$$

$$\sum_{n \in N} V_{n,m} \leq \mathbb{V}_m, \quad \forall m \in M \quad (33)$$

$$V_{n,m} \geq 0, \quad \forall n \in N, \forall m \in M \quad (34)$$

$$V_{n,m} \in \mathbb{Z}, \quad \forall n \in N, \forall m \in M \quad (35)$$

Onde:

- $N$ : conjunto dos navios considerados;
- $M$ : conjunto dos cursos considerados;
- $Ind_{n,m}^{atual}$ : índice atual do curso  $m$ , para o navio  $n$  no momento anterior a distribuição,  $n \in N$  e  $m \in M$ ;
- $Ind_{n,m}^{ideal}$ : índice ideal do curso  $m$ , para o navio  $n$ ,  $n \in N$  e  $m \in M$ ;
- $Ind_{n,m}^{min}$ : índice mínimo do curso  $m$ , para o navio  $n$ ,  $n \in N$  e  $m \in M$ ;
- $V_{n,m}$ : total de vagas do curso  $m$  distribuídas para o navio  $n$ ,  $n \in N$  e  $m \in M$ ;
- $\mathbb{V}_m$ : total de vagas do curso  $m$  que serão distribuídas para os navios,  $m \in M$ .

A primeira restrição garante que nenhum navio tenha um índice abaixo do índice mínimo após a distribuição de vagas. A segunda restrição impede que sejam alocadas mais vagas que o total disponível para cada curso. A terceira e quarta restrição dizem que as vagas são números inteiros e não negativos. Para linearizar o valor absoluto na função

objetivo, foi utilizada uma variável auxiliar  $Z_{n,m} \geq 0$  para cada navio e curso, de forma que o módulo fosse substituído por:

$$Ind_{n,m}^{atual} + V_{n,m} - Ind_{n,m}^{ideal} \leq Z_{n,m}, \quad \forall n \in N, \forall m \in M \quad (36)$$

$$-(Ind_{n,m}^{atual} + V_{n,m} - Ind_{n,m}^{ideal}) \leq Z_{n,m}, \quad \forall n \in N, \forall m \in M \quad (37)$$

$$Z_{n,m} \geq 0, \quad \forall n \in N, \forall m \in M \quad (38)$$

Onde:

- $Z_{n,m}$ : variável auxiliar que representa o desvio absoluto entre o índice resultante e o índice ideal do curso  $m$  no navio  $n$ .

E a função objetivo passou a ser:

$$\min \sum_{n \in N} \sum_{m \in M} Z_{n,m} \quad (39)$$

Nesse modelo, portanto, o decisor procura uma distribuição de vagas que, em um contexto determinístico, aproxima ao máximo os índices de cada navio e curso de seus respectivos valores ideais, garantindo simultaneamente que nenhum índice fique abaixo do mínimo estabelecido e que o total de vagas utilizadas em cada curso não exceda o limite disponível.

### 3.7.2 Modelo 2: PLI + Buffer (Opinião de Especialista)

Para este modelo foi incluído um *buffer* para servir como uma margem de segurança, sendo este aplicado na primeira restrição, de forma a garantir que a quantidade de cursados em determinado curso não fique abaixo do índice mínimo até a próxima distribuição anual de vagas, caso ocorram eventos imprevistos como desembarques.

Para cada curso, em cada navio, foi elaborado um *buffer* específico. Este valor foi obtido através de uma entrevista com o especialista responsável pelo gerenciamento dos cursos nos navios da amostra. Com base em sua experiência, percepção e intuição, o especialista atribuiu um valor de *buffer* para cada curso e navio. Assim, o modelo busca não só atingir o ideal, mas também se aproximar de um patamar de segurança, ainda que sejam empregadas mais vagas que o modelo 1.

Função Objetivo do Modelo 2:

$$\min \sum_{n \in N} \sum_{m \in M} |Ind_{n,m}^{atual} + V_{n,m} - Ind_{n,m}^{ideal}| \quad (40)$$

Restrições do Modelo 2:

$$Ind_{n,m}^{atual} + V_{n,m} \geq Ind_{n,m}^{min} + B_{n,m}, \quad \forall n \in N, \forall m \in M \quad (41)$$

$$\sum_{n \in N} V_{n,m} \leq \mathbb{V}_m, \quad \forall m \in M \quad (42)$$

$$V_{n,m} \geq 0, \quad \forall n \in N, \forall m \in M \quad (43)$$

$$V_{n,m} \in \mathbb{Z}, \quad \forall n \in N, \forall m \in M \quad (44)$$

Onde:

- $B_{n,m}$ : buffer de vagas atribuído pelo especialista no navio  $n$  para o curso  $m$ ,  $n \in N, m \in M$ , sendo um parâmetro inteiro e não negativo.

A primeira restrição garante que as vagas alocadas sejam suficientes para superar o índice mínimo com uma margem de segurança, as demais restrições permanecem iguais ao do modelo 1. A função objetivo é idêntica ao modelo anterior, e o termo de valor absoluto foi linearizado da mesma forma, por meio da variável auxiliar  $Z_{n,m}$ .

O Modelo 2 representa uma versão mais conservadora do Modelo 1, pois ao incorporar o *buffer* definido pelo especialista, ele prioriza a manutenção de uma folga de segurança acima do índice mínimo em cada curso e navio, aceitando o uso de um número maior de vagas.

### 3.7.3 Modelo 3: PLI + Simulações Estocásticas + $VaR_{0.71}$

Este modelo foi elaborado de forma a incorporar, de maneira explícita, a incerteza dos dados históricos por meio de simulações estocásticas e de uma restrição baseada em medida de risco do tipo VaR, calculada a partir dessas simulações. Foram geradas  $W=100$  simulações para os próximos 12 meses ( $T$ ), para cada curso  $m \in M$  de cada navio  $n \in N$ , conforme descrito na seção 3.5. A função objetivo minimiza, de forma agregada, o desvio absoluto entre o índice resultante (simulado + vagas alocadas) e o índice ideal, com aplicação de PLI combinada com uma medida de risco do tipo VaR. Embora o VaR seja amplamente utilizado no contexto financeiro, aqui é adaptado à gestão de capacitação naval, sendo aplicado a simulações estocásticas de séries temporais de contagem.

Função Objetivo do Modelo 3:

$$\min \frac{1}{|W|} \sum_{w \in W} \left( \frac{1}{|T|} \sum_{t \in T} \sum_{n \in N} \sum_{m \in M} |Ind_{n,m,t,w}^{sim} + V_{n,m} - Ind_{n,m}^{ideal}| \right) \quad (45)$$

Restrições do Modelo 3:

$$V_{n,m} \geq VaR_{0.71}(\Delta_{n,m,t}), \quad \forall n \in N, \forall m \in M, \forall t \in T \quad (46)$$

$$\sum_{n \in N} V_{n,m} \leq \mathbb{V}_m, \quad \forall m \in M \quad (47)$$

$$V_{n,m} \geq 0, \quad \forall n \in N, \forall m \in M \quad (48)$$

$$V_{n,m} \in \mathbb{Z}, \quad \forall n \in N, \forall m \in M \quad (49)$$

Onde:

- $T$ : conjunto dos meses simulados ( $|T| = 12$ ).
- $W$ : conjunto dos cenários simulados ( $|W| = 100$ ).
- $Ind_{n,m,t,w}^{sim}$ : índice simulado no mês  $t \in T$ , para o navio  $n \in N$ , no curso  $m \in M$ , no cenário  $w \in W$ , antes da nova alocação de vagas.
- $VaR_{0,71}(\Delta_{n,m,t})$ : valor de VaR no nível de 71% aplicado a distribuição empírica dos déficits simulados  $\Delta_{n,m,t,w}$ , associado ao par navio e curso  $(n, m)$  no mês  $t$ .

A restrição baseada em percentil implementa o  $VaR_{0,71}$  sobre a distribuição das diferenças

$$\Delta_{n,m,t,w} = Ind_{n,m}^{min} - Ind_{n,m,t,w}^{sim}, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (50)$$

que podem ser interpretadas como déficits quando positivas (índice simulado abaixo do mínimo) e como folgas quando negativas. Para uma combinação  $(n, m, t)$ , calcula-se o percentil de ordem 0,71 dessa distribuição empírica  $\{\Delta_{n,m,t,w} : w \in W\}$ , obtendo-se o valor de  $VaR_{0,71}(\Delta_{n,m,t})$ . Essa restrição exige que as vagas alocadas,  $V_{n,m}$ , sejam no mínimo iguais a esse valor, o que na prática estabelece o piso de alocação compatível com o risco de o índice ficar abaixo do mínimo em uma fração relevante dos cenários. O nível de confiança de 71% foi determinado empiricamente: inicialmente testou-se o percentil 90, mas o modelo tornou-se inviável; o percentil foi então reduzido gradualmente (85, 80, 75, ...) até 71%, ponto a partir do qual a solução passou a ser viável. Todas as demais restrições permanecem idênticas aos modelos anteriores.

De forma semelhante aos modelos anteriores, a função objetivo passou por um processo de linearização, com a inclusão de uma variável auxiliar  $Z_{n,m,t,w} \geq 0$  para cada navio, curso, mês e cenário, de forma que o módulo fosse substituído por:

$$Ind_{n,m,t,w}^{sim} + V_{n,m} - Ind_{n,m}^{ideal} \leq Z_{n,m,t,w}, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (51)$$

$$-(Ind_{n,m,t,w}^{sim} + V_{n,m} - Ind_{n,m}^{ideal}) \leq Z_{n,m,t,w}, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (52)$$

Onde:

- $Z_{n,m,t,w}$ : variável auxiliar que representa o desvio absoluto entre o índice resultante e o índice ideal no navio  $n$ , para o curso  $m$ , no mês  $t$  e no cenário  $w$ .

E a função objetivo passou a ser:

$$\min \frac{1}{|W|} \sum_{n \in N} \left( \frac{1}{|T|} \sum_{t \in T} \sum_{n \in N} \sum_{m \in M} Z_{n,m,t,w} \right) \quad (53)$$

O Modelo 3 combina a estrutura de PLI dos modelos anteriores com a incerteza capturada por simulações estocásticas e uma restrição de risco  $Var_{0,71}$ , garantindo que, em uma fração significativa dos cenários, as vagas alocadas sejam suficientes para compensar os déficits simulados em relação ao índice mínimo, ao mesmo tempo em que minimiza o desvio médio em relação aos índices ideais.

### 3.7.4 Modelo 4: PLI + Simulações Estocásticas + $Var_{0,90}$

Este modelo é uma adaptação do modelo anterior, para trabalhar com um nível de confiança mais elevado,  $Var_{0,90}$ , o que significa considerar o percentil 90% dos déficits simulados. Para evitar a inviabilidade do modelo, dado o limite de vagas disponíveis, foi introduzida uma variável de excesso,  $E_{n,m}$ , com uma penalização,  $P$ , na função objetivo, permitindo uma violação controlada da restrição de VaR. O excesso indica o *trade-off* entre cumprir integralmente a restrição e aceitar um pequeno nível de violação controlada, sempre sob penalização. O coeficiente de penalização é um valor elevado, de forma que o modelo utilize o excesso somente nos casos em que não haja alternativa viável. Os valores testados de  $P$  variaram de 1.000, 10.000 e 100.000.

Função objetivo 4:

$$\min \frac{1}{|W|} \sum_{w \in W} \left( \frac{1}{|T|} \sum_{t \in T} \sum_{n \in N} \sum_{m \in M} |Ind_{n,m,t,w}^{sim} + V_{n,m} - Ind_{n,m}^{ideal}| \right) + P \sum_{n \in N} \sum_{m \in M} E_{n,m} \quad (54)$$

Restrições do modelo 4:

$$V_{n,m} + E_{n,m} \geq Var_{0,90}(\Delta_{n,m,t}), \quad \forall n \in N, \forall m \in M, \forall t \in T \quad (55)$$

$$\sum_{n \in N} V_{n,m} \leq V_m, \quad \forall m \in M \quad (56)$$

$$V_{n,m}, E_{n,m} \geq 0, \quad \forall n \in N, \forall m \in M \quad (57)$$

$$V_{n,m}, E_{n,m} \in \mathbb{Z}, \quad \forall n \in N, \forall m \in M \quad (58)$$

Onde:

- $E_{n,m}$ : variável de excesso associada à restrição de VaR para o navio  $n$  e o curso  $m$ , inteira e não negativa, representando a violação permitida do piso definido por  $VaR_{0,90}$ , penalizada na função objetivo pelo coeficiente  $P$
- $P$ : coeficiente de penalização associado ao uso de  $E_{n,m}$ , escolhido de forma suficientemente alta para desencorajar violações, salvo em casos em que a restrição de  $VaR_{0,90}$  não possa ser satisfeita apenas com  $V_{n,m}$ .

A restrição baseada em percentil implementa o  $VaR_{0,90}$  sobre a distribuição das diferenças

$$\Delta_{n,m,t,w} = Ind_{n,m}^{min} - Ind_{n,m,t,w}^{sim}, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (59)$$

que podem ser interpretadas como déficits quando positivas (índice simulado abaixo do mínimo) e como folga quando negativas. Para uma combinação  $(n, m, t)$ , calcula-se o percentil de ordem 0.90 dessa distribuição empírica  $\{\Delta_{n,m,t,w} : w \in W\}$ , obtendo-se o valor de  $VaR_{0,90}(\Delta_{n,m,t})$ . Essa restrição exige que as vagas alocadas,  $V_{n,m} + E_{n,m}$ , sejam no mínimo iguais a esse valor, estabelecendo um piso de alocação compatível com um nível de confiança de 90%, em que a variável  $E_{n,m}$  representa vagas adicionais necessárias além das disponíveis. As demais restrições permanecem iguais as anteriores, ocorrendo na última a inclusão de  $E_{n,m} \geq 0$ . A linearização foi feita de forma idêntica ao modelo anterior, por meio da variável auxiliar  $Z_{n,m,t,w}$ .

O Modelo 4 é um ajuste do modelo anterior, ao combinar um nível de confiança para o  $VaR_{0,90}$  com a possibilidade de violação controlada por meio da variável de excesso  $E_{n,m}$ . Ele é mais adequado a situações em que o decisor deseja privilegiar a segurança em relação ao atendimento do índice mínimo, sabendo que os recursos (vagas disponíveis) podem não ser suficientes para cumprir integralmente essa política de risco em todos os casos.

### 3.7.5 Modelo 5: PLI + Simulações Estocásticas + CVaR

Este modelo foi elaborado para verificar a alocação de vagas considerando a média dos piores cenários simulados. Em vez de controlar apenas um ponto de corte da distribuição (como no VaR), passou-se a controlar a média das perdas na cauda, por meio da medida de risco CVaR. A ideia foi garantir que, mesmo nos cenários mais

desfavoráveis, o atendimento (índice resultante após a alocação) não ficasse, em média, abaixo do índice mínimo estabelecido para cada par navio e curso. Para isso, foi definida a variável de perda:

$$Y_{n,m,t,w} = -(V_{n,m} + Ind_{n,m,t,w}^{sim}), \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (60)$$

onde  $V_{n,m}$  é o número de vagas alocadas ao navio  $n$  no curso  $m$ , e  $Ind_{n,m,t,w}^{sim}$  é o índice simulado de militares com o curso  $m$  no navio  $n$ , no mês  $t$ , sob o cenário  $w$ . Dessa forma, valores menores de atendimento ( $V_{n,m} + Ind_{n,m,t,w}^{sim}$ ) correspondem a valores maiores de  $Y_{n,m,t,w}$ : cenários com pouco atendimento são interpretados como “perdas” mais elevadas. Isso permitiu aplicar o CVaR sobre  $Y_{n,m,t,w}$ , tratando quedas no atendimento como situações de risco.

Foi adotada a formulação amostral de Rockafellar e Uryasev (2000) para o CVaR. Introduziu-se para cada par de navio e curso  $(n, m)$ , uma variável auxiliar  $\zeta_{n,m} \in \mathbb{R}$ , que representa o  $VaR_\alpha$  (ponto de corte) da distribuição de  $Y_{n,m,t,w}$ , e variáveis auxiliares  $u_{n,m,t,w} \geq 0$ , que representam o excesso de perda em cada cenário e período. Essas variáveis obedecem às seguintes relações:

$$u_{n,m,t,w} \geq Y_{n,m,t,w} - \zeta_{n,m}, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (61)$$

$$\zeta_{n,m} + \frac{1}{(1-\alpha)|W||T|} \sum_{w \in W} \sum_{t \in T} u_{n,m,t,w} \leq -Ind_{n,m}^{min}, \quad \forall n \in N, \forall m \in M \quad (62)$$

O termo à esquerda em (62) é a aproximação amostral do  $CVaR_\alpha$  calculado sobre os valores  $Y_{n,m,t,w}$ ,  $t \in T, w \in W$ , para um navio  $n$  e curso  $m$  fixos. Como  $Y_{n,m,t,w} = -(V_{n,m} + Ind_{n,m,t,w}^{sim})$ , impor  $CVaR_\alpha(Y_{n,m,t,w}) \leq -Ind_{n,m}^{min}$  equivale a garantir que a média dos piores cenários de atendimento ( $V_{n,m} + Ind_{n,m,t,w}^{sim}$ ) seja pelo menos igual ao índice mínimo  $Ind_{n,m}^{min}$  daquele par de navio e curso. Em outras palavras, mesmo quando se consideram os cenários mais desfavoráveis, o atendimento médio na cauda da distribuição não deve ficar abaixo do nível mínimo desejado. Logo o modelo 5 ficou da seguinte forma:

Função Objetivo 5:



$$\min \frac{1}{|W|} \sum_{w \in W} \left( \frac{1}{|T|} \sum_t \sum_{n \in N} \sum_{m \in M} |Ind_{n,m,t,w}^{sim} + V_{n,m} - Ind_{n,m}^{ideal}| \right) \quad (63)$$

Restrições do Modelo 5:

$$\zeta_{n,m} + \frac{1}{(1-\alpha)|W||T|} \sum_{w \in W} \sum_{t \in T} u_{n,m,t,w} \leq -Ind_{n,m}^{min}, \quad \forall n \in N, \forall m \in M \quad (64)$$

$$u_{n,m,t,w} \geq -(V_{n,m} + Ind_{n,m,t,w}^{sim}) - \zeta_{n,m}, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (65)$$

$$\sum_{n \in N} V_{n,m} \leq \mathbb{V}_m, \quad \forall m \in M \quad (66)$$

$$u_{n,m,t,w} \geq 0, \quad \forall n \in N, \forall m \in M, \forall t \in T, \forall w \in W \quad (67)$$

$$V_{n,m} \geq 0, \quad \forall n \in N, \forall m \in M \quad (68)$$

$$V_{n,m} \in \mathbb{Z}, \quad \forall n \in N, \forall m \in M \quad (69)$$

Onde:

- $\zeta_{n,m}$ : variável auxiliar contínua que representa o  $VaR_\alpha$  da distribuição de  $Y_{n,m,t,w}$  para o navio  $n$  e o curso  $m$ , atuando como ponto de corte que separa a cauda de probabilidade  $(1 - \alpha)$  dos piores cenários de atendimento;
- $u_{n,m,t,w}$ : variável auxiliar contínua não negativa que representa o excesso de perda no cenário  $(t, w)$ , medindo quanto  $Y_{n,m,t,w}$  ultrapassa o ponto de corte  $\zeta_{n,m}$ ;
- $\frac{1}{(1-\alpha)|W||T|}$ : fator de normalização que converte a soma dos excessos  $u_{n,m,t,w}$  na média das perdas na cauda, compondo o termo de  $CVaR_\alpha$  em conjunto com  $\zeta_{n,m}$ ;

Nos modelos baseados em VaR, o risco foi controlado por meio de um valor que delimitava apenas um ponto de corte na cauda, onde uma fração dos cenários podiam violar o índice mínimo, mas sem levar em conta quão severas são essas violações. No caso do CVaR, o foco deslocou-se para a média das perdas na cauda, pois em vez de considerar apenas o ponto de corte, passou-se a considerar a severidade média dos cenários extremos.

O parâmetro  $\alpha$  foi calibrado empiricamente, iniciou-se com  $\alpha = 0,70$ , mas o problema tornou-se inviável, dado o número limitado de vagas disponíveis. O parâmetro foi então reduzido gradualmente até  $\alpha = 0,62$ , valor a partir do qual o modelo se tornou viável. No CVaR,  $\alpha$  controla o tamanho da cauda considerada, onde a fração  $(1 - \alpha)$  corresponde à proporção dos piores cenários incluídos na média. Por exemplo,  $\alpha = 0,70$  implica considerar a média dos 30% piores cenários, enquanto  $\alpha = 0,62$  corresponde à média dos 38% piores cenários. Quando a cauda é menor (isto é,  $\alpha$  é maior), o CVaR se concentra em um subconjunto mais extremo da distribuição, com pouca ou nenhuma “diluição” por cenários menos severos; isso tende a produzir valores mais altos de  $CVaR_\alpha$  e torna a restrição de risco mais difícil de ser satisfeita, tornando o critério mais rigoroso. Por outro lado, ao aumentar a cauda (reduzir  $\alpha$ ), os cenários muito ruins passam a ser combinados, na média, com cenários menos críticos, o que reduz o valor do CVaR e torna a restrição mais branda.

Assim como nos modelos anteriores, o módulo presente na função objetivo (63) é linearizado por meio da variável auxiliar  $Z_{n,m,t,w}$ , utilizando a mesma estrutura de desigualdades apresentada anteriormente.

## 4 RESULTADOS

Os modelos 1 e 2 foram aplicados sobre os dados das vagas distribuídas em 2023, e os modelos 3, 4 e 5 foram aplicados sobre 100 simulações geradas de cursados para os próximos 12 meses, utilizando a sugestão de série baseada em Random Walk.

### 4.1 RESULTADOS DAS PREVISÕES

Foram geradas 100 simulações de 12 meses subsequentes para cada curso de cada navio, em gráficos do tipo fanchart, os quais contêm: a série histórica, a média da série histórica, a mediana e média simuladas, além das faixas dos percentis 40-60%, 25-75% e 5-95%. Esses gráficos serviram como instrumento de validação visual pelo especialista, tendo em vista que a formulação das simulações foi elaborada de forma empírica, levando em consideração a amostra curta e comportamento dos dados da amostra, além das observações e expectativas do especialista, conforma critérios discutidos na seção 3.6.

Na avaliação, o especialista observou os seguintes pontos de razoabilidade: ancoragem da mediana no patamar mais recente do histórico, o alargamento progressivo das faixas de percentis com o horizonte, refletindo a incerteza acumulada e a assimetria plausível à direita, compatível com dados de contagem (média ligeiramente acima da mediana e banda inferior limitada pelo zero). Também foram considerados eventos do histórico, como platôs e meses zerados, que se refletiram em faixas inferiores mais próximas do piso em alguns cursos.

De modo geral, o julgamento foi de que as simulações eram razoáveis pois os fancharts preservaram o nível recente das séries, comunicaram a incerteza de forma transparente e reproduziram padrões esperados para contagens. A partir desse parecer, os cenários simulados foram usados como base para os Modelos estocásticos, nos quais a incerteza foi tratada por medidas de risco. Como exemplo ilustrativo, foi apresentado o curso 12 na figura 10, discutido na introdução, demais cursos encontram-se no apêndice D.




Figura 10 – Simulações para o Curso 12

## 4.2 RESULTADOS DOS MODELOS OTIMIZADOS

Os modelos foram aplicados para os 18 cursos de cada um dos 3 navios, contabilizando um total de 54 cursos, levando-se em consideração os seus respectivos índices. Após a distribuição ótima foram observados os seguintes resultados envolvendo todos os cursos e navios da amostra, atentando para o atingimento dos índices ideais, conforme gráfico abaixo:




Figura 11 - Gráfico sobre atingimento do índice ideal nos cursos após a distribuição.

De acordo com a figura 11, o modelo 1 apresentou o melhor desempenho, com uma maior quantidade de cursos atingindo o índice ideal (aproximadamente 94% do total de cursos da amostra), além de restar somente 3 cursos abaixo deste índice. Após ele, o modelo 2 foi o que apresentou o melhor desempenho, com a segunda maior quantidade de cursos atingindo o índice ideal (cerca de 91% do total de cursos), restando 5 cursos abaixo do ideal. Os modelos 3, 4 e 5, que utilizaram as simulações estocásticas apresentaram desempenho inferior à distribuição real, tanto no atingimento de índices ideais, como na quantidade de cursos que ficaram abaixo deste índice após a distribuição. Em todos os tipos de distribuições não foram observados casos de cursos abaixo do índice mínimo.

Dos cursos que não atingiram o índice ideal, foram contabilizadas quantas vagas faltaram para o seu atingimento, por navio e tipo de distribuição. Os casos em que este índice foi alcançado estão representados por -. A distribuição completa de todas as vagas por navio e modelo, juntamente com o atingimento dos índices ideais, encontra-se no Apêndice E.

Tabela 7 - Vagas que faltaram para atingir o índice ideal no Navio 1 após a alocação, por curso e por tipo de distribuição.

Navio	Curso	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
1	Curso 1	1	-	-	-	-	-
	Curso 4	-	-	-	7	-	8
	Curso 12	4	7	6	5	-	5
	Curso 13	-	-	-	6	6	6
	Curso 15	-	-	-	1	1	1
	Curso 16	-	-	-	2	2	2
	Curso 17	-	-	-	1	1	1

Tabela 8 - Vagas que faltaram para atingir o índice ideal no Navio 2 após a alocação, por curso e por tipo de distribuição.

Navio	Curso	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
2	Curso 1	1	-	-	-	-	-
	Curso 2	-	-	-	1	1	1
	Curso 4	2	-	-	-	-	-
	Curso 12	3	10	6	7	7	7
	Curso 15	8	-	5	4	-	4

Tabela 9 - Vagas que faltaram para atingir o índice ideal no Navio 3 após a alocação, por curso e por tipo de distribuição.

Navio	Curso	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
3	Curso 11	-	-	-	2	2	2
	Curso 12	10	-	5	5	11	5
	Curso 15	6	7	4	4	12	4
	Curso 17	-	-	-	4	4	4

Os resultados evidenciam que os modelos propostos são capazes de orientar a distribuição de vagas de forma consistente com as metas de qualificação, mensuradas pelo atingimento dos índices ideais e pela ausência de índices abaixo do mínimo, ao mesmo tempo em que explicitam o trade-off entre desempenho agregado e robustez quando se incorporam mecanismos estocásticos e medidas de risco. Dado que diferentes configurações de modelagem podem produzir níveis distintos de atingimento do índice ideal, torna-se necessário avaliar também as implicações associadas ao uso de recursos e à eficiência econômica dessas soluções. Assim, no item 4.3, é apresentada a análise de custo das distribuições obtidas, permitindo comparar os modelos sob a ótica do dispêndio requerido para alcançar os níveis de desempenho observados.

### 4.3 ANÁLISE DE CUSTO

Os modelos foram formulados para maximizar o atendimento de índices sem otimizar custo. Os valores de custo que serão apresentados, são apurados sobre as soluções obtidas e foram interpretados apenas como diagnóstico gerencial, não como desempenho de otimização. Para esta análise, considerou-se como total de recursos disponíveis o valor do custo individual de cada vaga em cada curso, multiplicado pelas vagas que seriam distribuídas, dando um total de R\$ 132.791,93. Com base nisso, foi possível entender o quanto de recurso foi utilizado em cada modelo, através da contabilização das vagas alocadas e a multiplicação pelos seus respectivos custos individuais. Para a distribuição real foi considerado o valor total, pois todas as vagas foram distribuídas, não havendo sobras. Os custos com as distribuições estão ilustrados abaixo:




Figura 12 - Gráfico sobre o valor gasto na distribuição de vagas.

Observando-se o gráfico, é possível notar que o modelo 3 foi o que teve o menor custo com a distribuição ótima de vagas, empregando aproximadamente 46% dos recursos considerados disponíveis, sendo seguido, por ordem de economia, pelos modelos 5, 1, 2 e 4. Em todos os casos, os recursos empregados foram inferiores ao que foi utilizado na prática.

Após a distribuição realizada pelos modelos, considerando as vagas disponíveis para a distribuição, foi observado que houve sobra de vagas, então elas foram contabilizadas e foram calculados os seus respectivos valores, a fim de estimar o quanto

de recurso restaria após a aplicação de cada modelo. Além disso, ao verificar quantas vagas seriam necessárias para atingir os índices ideais nos cursos que não conseguiram, após as distribuições, foi possível estimar a quantidade de recurso que seria necessário ainda para o atingimento desses índices, conforme gráfico abaixo:




Figura 13 - Gráfico comparativo entre os valores que sobraram após a distribuição e os necessários para atingir os índices ideais restantes.

De acordo com o gráfico, é possível notar que em todos os modelos, com exceção do modelo 4, os recursos que sobraram após as distribuições seriam suficientes para atender o necessário para que os demais cursos atingissem os seus respectivos índices ideais. Na distribuição real não há sobra, pois todas as vagas foram alocadas. Após isso, foi possível fazer uma análise de quanto que sobraria de recurso após a utilização das sobras dos modelos para o atingimento dos índices ideais restantes, de acordo com o gráfico abaixo:



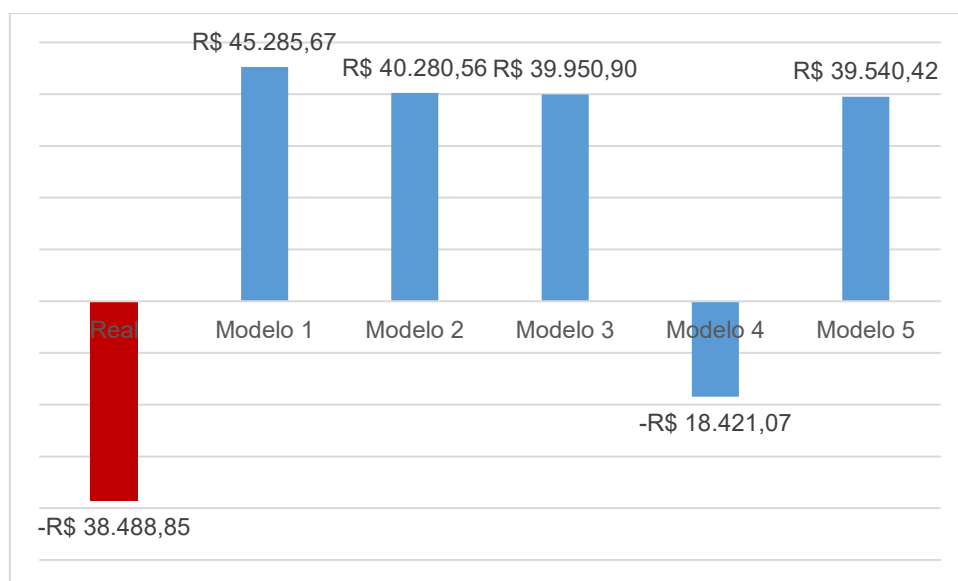


Figura 14 - Gráfico sobre valores que restaram após aplicação da sobra inicial para atingir os índices ideais restantes.

Segundo os dados, o modelo 1 foi o que apresentaria a maior sobra, caso os recursos remanescentes da distribuição das vagas fossem utilizados para adquirir novas vagas para os cursos restantes, que não haviam atingido os índices ideais após a alocação inicial. O modelo 2 foi o que apresentaria a segunda maior sobra, seguido dos modelos 3 e 5, na ordem decrescente. O modelo 4 não teria recursos suficientes para atender a todas as demandas remanescentes de índices ideais, pois a necessidade de recursos para isso seria superior ao que sobrou após a distribuição, sendo a diferença apresentada no gráfico com valores negativos. Na distribuição real não sobraram vagas e nem recursos, logo, o total estimado para o atingimento dos ideais nesse caso também está representado por valores negativos no gráfico.

De posse dos valores utilizados nas distribuições, e dos custos necessários para atingir os índices ideais após elas ocorrerem, foi possível estimar um custo global para verificar o quanto seria necessário investir para que todos os índices ideais fossem alcançados, independentemente do tipo de distribuição. Esse custo seria composto pela soma do valor utilizado pelo modelo na distribuição, com o valor ainda necessário após a ela, para o atingimento dos índices ideais restantes, conforme ilustrado abaixo:




Figura 15 - Gráfico com o valor total necessário para que todos os cursos atinjam o índice ideal, considerando o valor gasto na distribuição somado ao valor necessário para atingir os índices ideais restantes.

Dos tipos de distribuições realizadas, a do modelo 1 mostrou-se mais econômica, com um melhor aproveitamento dos recursos, utilizando cerca de 51% do valor total da distribuição real, sendo seguida pelos modelos 2, 3, 5 e 4, por ordem de economia. Todos os modelos apresentaram um custo global inferior ao utilizado na distribuição real.

A partir dos resultados obtidos, foi confeccionada uma tabela-resumo, onde encontra-se um ranking entre os modelos e a distribuição real, do melhor ao pior, comparando: atendimento dos índices ideais após a primeira alocação de vagas, recursos remanescentes após essa alocação (1ª sobra), recursos remanescentes após o uso da 1ª sobra nos cursos que não atingiram o ideal na distribuição (2ª sobra), recursos totais alocados para que todos os cursos atinjam o ideal. Não houve casos de curso abaixo do índice mínimo após qualquer tipo de distribuição. Quando não restou recurso, foi colocado um traço -.

Tabela 10 – Ranking dos modelos

Modelo	Atendimento Índ. ideais (1=melhor)	1ª sobra (1=maior)	2ª sobra (1=maior)	Custo total aplicado (1=menor)
<b>Modelo 1 (PLI)</b>	1	3	1	1
<b>Modelo 2 (PLI+Buf)</b>	2	5	2	2
<b>Modelo 3 (VaR 0,71)</b>	5 (empate)	1	3	3
<b>Modelo 4 (VaR 0,90)</b>	4	2	-	5
<b>Modelo 5 (CVaR)</b>	5 (empate)	4	4	4
<b>Real</b>	3	-	-	6

## 5 DISCUSSÃO

Foi realizada uma análise crítica e comparativa dos diferentes modelos testados para alocação de vagas, observando: o atingimento de índices, uso de recursos – gasto inicial e sobra após alocação, robustez operacional e viabilidade/praticabilidade. Com isso, foi evidenciado o *trade-off* entre cobertura e custo, além da resiliência frente a imprevistos, tomando a distribuição real como referência. As comparações de custo são descritivas, pois os valores não integraram a função objetivo dos modelos; a análise comparativa entre modelos é, portanto, conduzida principalmente por cobertura dos índices, os valores serviram somente como evidências auxiliares.

### 5.1 INTERPRETAÇÃO DOS RESULTADOS.

De forma geral, pode-se dizer que todos os modelos propostos ofereceram uma vantagem em relação ao método atualmente empregado, quando avaliados sob a ótica de eficiência de alocação de vagas (relação entre cobertura dos índices e recursos utilizados). Mesmo nos casos em que a cobertura após a distribuição inicial não tenha superado a obtida na distribuição real para todos os cursos, os modelos indicaram que seria possível alcançar níveis semelhantes ou superiores de atendimento utilizando menos recursos em comparação à prática vigente.

Do ponto de vista do atingimento de índices por curso na alocação inicial, destacaram-se os Modelos 1 e 2, que superaram a distribuição real no número de índices ideais atendidos e reduziram o número de cursos pendentes para o atendimento integral. Esses resultados colocam os Modelos 1 e 2 na fronteira de eficiência entre cobertura e custo, sendo particularmente indicados para decisões no momento da distribuição.

Sob a perspectiva operacional, os modelos oferecem um ponto de partida quantitativo para o gestor, ao substituir um procedimento predominantemente subjetivo por um processo estruturado e reproduzível. De acordo com relato do especialista, a distribuição atual demanda cerca de uma semana; com o uso dos modelos, o responsável passa a dispor de propostas iniciais consistentes para auxílio a decisão, o que otimiza o tempo de análise e ajuda na padronização de critérios ao longo dos navios e cursos, preservando um espaço para ajustes gerenciais.

Os modelos 3, 4 e 5, baseados em simulações estocásticas incorporam a incerteza através de medidas de risco no momento da distribuição, além de se mostrarem úteis na fase de planejamento, quando é feita a solicitação para o ano seguinte, pois incorporam a

incerteza dos próximos doze meses a partir do comportamento dos dados históricos. Dessa forma, atuam como um instrumento de antecipação de possíveis necessidades, realimentando o ciclo decisório com evidências quantitativas em um ponto do processo que hoje também é conduzido por julgamento subjetivo.

## **5.2 PONTOS FORTES E LIMITAÇÕES DOS MODELOS.**

A partir dos resultados foi possível organizar os pontos fortes e limitações de cada modelo, além de avaliar as recomendações do uso de cada um deles conforme as prioridades definidas na gestão do processo (eficiência no atingimento dos índices, resiliência a imprevistos ou restrições orçamentárias).

### **5.2.1 Modelo 1: PLI**

O Modelo determinístico utilizou somente os dados das vagas as serem distribuídas e os índices no momento da distribuição. Apresentou como pontos fortes um melhor compromisso entre cobertura e custo dentre as alternativas, além de sobra financeira elevada que ainda permite elevar cursos remanescentes ao ideal. Como limitações, observou-se que ele não protege contra desembarques imprevistos: se o ideal já foi atingido, o modelo não aloca vagas adicionais, podendo cair abaixo do mínimo em casos de cursos com índices ideais e mínimos baixos, além de não haver componente de risco, pois decide para o cenário médio de hoje. A sugestão de uso é quando orçamento for restrito e ambiente estável.

### **5.2.2 Modelo 2: PLI + Buffer (Opinião de Especialista)**

O Modelo determinístico, de forma semelhante ao anterior, utilizou os dados das vagas as serem distribuídas e os índices no momento da distribuição, acrescidos da opinião de especialista incluída na restrição de atendimento do índice mínimo em forma de buffer. Apresentou como pontos fortes uma solução para a lacuna do Modelo 1 para os casos de saídas inopinadas, como um tipo de reserva, de forma a evitar que haja índices abaixo do mínimo até a próxima distribuição, usando mais recursos que o modelo anterior para gerar uma cobertura de segurança dos índices. Como limitações apresentou um custo inicial maior que o Modelo 1, e dependência de calibração regular do buffer, de acordo com a observação dos dados históricos. Um buffer maior aumenta o custo e pode gerar

excessos. A sugestão de uso é quando a prioridade for operar com estabilidade e evitar déficits entre as distribuições anuais.

### **5.2.3 Modelo 3: PLI + Simulações Estocásticas + $Var_{0,71}$**

Diferentemente dos modelos anteriores, este utilizou-se dos dados históricos para realização de simulações estocásticas para subsidiar a distribuição feita com PLI baseada em riscos. Apresentou como pontos fortes uma boa eficiência no custo inicial pois apresentou menor uso de recursos nessa fase, inclui restrições de risco abrangendo um nível de 71% dos possíveis cenários. Como limitações, observou-se uma cobertura inicial inferior após a alocação inicial, pois ficou abaixo da distribuição real. O  $\alpha = 0,71$  foi um nível escolhido por viabilidade do modelo, além de poder transmitir uma falsa segurança se a cauda tiver eventos raros e severos, pois eles não são considerados. A sugestão de uso é quando for incluir risco e a prioridade for um custo menor, ao invés da cobertura dos índices.

### **5.2.4 Modelo 4: PLI + Simulações Estocásticas + $Var_{0,90}$**

De forma semelhante ao modelo anterior, utilizou-se dos dados históricos para realização de simulações estocásticas juntamente com PLI baseada em riscos, porém elevando para 90% dos possíveis cenários, incluindo variável de excesso para viabilização do modelo. Apresentou como pontos fortes um nível de abrangência mais alto (90%), sendo mais conservador que o modelo anterior. Indica necessidades extras de vagas para aumentar a garantia de robustez do modelo, podendo aumentar a cobertura em alguns pontos. Como limitações, observou-se que custo da alocação inicial é muito elevado (o pior entre os modelos), e a variável de excesso foi acionada em 4 cursos, requerendo plausibilidade gerencial para obter vagas extras, além de continuar não considerando a severidade média dos piores casos. A sugestão de uso é quando foi exigido o atendimento de um quantil alto, valendo a pena somente no caso de ser possível alocações extras.

### **5.2.5 Modelo 5: PLI + Simulações Estocásticas + CVaR**

Fez uso das simulações nos mesmos moldes dos modelos 3 e 4, porém considerando como medida de risco a média dos piores casos, com escolha do  $\alpha$  mais conservador possível. Apresentou como pontos fortes a aversão a risco na cauda (CVaR)

que é adequada quando se deseja proteger contra a média dos piores cenários, além de ter boa eficiência do ponto de vista do custo na alocação inicial. Como limitações, observou-se que o custo total foi um pouco maior que os modelos 1 e 3, além de não converter a aversão a risco da média dos piores casos em melhor cobertura na alocação inicial, pois ficou abaixo da prática. A sugestão de uso é quando a prioridade for garantir a operação em cenários ruins, aceitando um leve aumento de custo para aumentar a resiliência.

Os pontos fortes, limitações e sugestões de uso foram compilados em uma única tabela:

Tabela 11 – Pontos fortes e limitações dos modelos

Modelo	Pontos fortes	Limitações	Sugestão de uso
<b>Modelo 1: PLI</b>	Melhor compromisso entre cobertura e custo dentre as alternativas. Sobra financeira elevada que ainda permite elevar cursos remanescentes ao ideal.	Não protege contra desembarques imprevistos: se o ideal já foi atingido, o modelo não aloca vagas adicionais, podendo cair abaixo do mínimo em casos de cursos com índices ideais e mínimos baixos. Não há componente de risco, pois decide para o cenário médio de hoje.	Orçamento restrito e ambiente estável.
<b>Modelo 2: PLI + Buffer (Opinião de Especialista)</b>	Apresenta uma solução para a lacuna do Modelo 1 para os casos de saídas inopinadas, como um tipo de reserva, de forma a evitar que haja índices abaixo do mínimo até a próxima distribuição. Usa mais recursos que o modelo anterior para gerar uma cobertura de segurança dos índices.	Há um custo inicial maior que o Modelo 1, e dependência de calibração regular do buffer, de acordo com a observação dos dados históricos. Um buffer mais aumenta o custo e pode gerar excessos.	Quando a prioridade for operar com estabilidade e evitar déficits entre as distribuições anuais.
<b>Modelo 3: PLI + Simulações Estocásticas + <math>Var_{0,71}</math></b>	Boa eficiência no custo inicial pois apresentou menor uso de recursos nessa fase, inclui restrições de risco abrangendo um nível de 71% dos possíveis cenários.	Apresentou uma cobertura inicial inferior após a alocação inicial, pois ficou abaixo da distribuição real. O $\alpha = 0,71$ foi um nível escolhido por viabilidade do modelo. Pode transmitir uma falsa segurança se a cauda tiver eventos raros e severos, pois eles não são considerados.	Quando for incluir risco e a prioridade for um custo menor, ao invés da cobertura dos índices.
<b>Modelo 4: PLI + Simulações Estocásticas + <math>Var_{0,90}</math></b>	Impõe nível de abrangência mais alto (90%), sendo mais conservador que o modelo anterior. Indica necessidades extras de vagas para aumentar a garantia de robustez do modelo, podendo aumentar a cobertura em alguns pontos.	O custo da alocação inicial é muito elevado (o pior entre os modelos). A variável de excesso foi acionada em 4 cursos, requerendo plausibilidade gerencial para obter vagas extras, além de continuar não considerando a severidade média dos piores casos.	Quando foi exigido o atendimento de um quantil alto, valendo a pena somente no caso de ser possível alocações extras.
<b>Modelo 5: PLI + Simulações Estocásticas + CVaR</b>	Apresentação da aversão a risco na cauda (CVaR) é adequada quando se deseja proteger contra a média dos piores cenários, e teve boa eficiência do ponto de vista do custo na alocação inicial.	O custo total foi um pouco maior que os modelos 1 e 3. Não converteu a aversão a risco da média dos piores casos em melhor cobertura na alocação inicial, pois ficou abaixo da prática.	Quando a prioridade for garantir a operação em cenários ruins, aceitando um leve aumento de custo para aumentar a resiliência.

Em síntese, se o objetivo for eficiência com cobertura alta com os dados disponíveis no momento da distribuição, sugere-se priorizar o Modelo 1 (ou 2, quando for importante a garantia contra desembarques); se a meta é minimizar custo inicial incluindo possibilidades futuras e medidas de risco, Modelo 3 e 5 são mais adequados; o Modelo 4 requer revisão de plausibilidade para o caso de alocações extras.

### 5.3 OBSERVAÇÕES SOBRE OS DADOS COLETADOS

As análises indicam bom desempenho do Modelo 1 tanto no atingimento dos índices quanto na utilização de recursos. Entretanto, observou-se que o mapa de cursados registra quem possui o curso, mas não necessariamente quem exerce a função que necessita daquela qualificação. Logo, alguns excessos observados em alguns cursos podem não ser tão significativos quanto parecem, influenciando na interpretação dos modelos, que alocam as vagas conforme a necessidade percebida.

Essa limitação se propaga para as simulações através da incerteza de entrada (*input uncertainty*): onde os parâmetros são estimados a partir de dados escassos e potencialmente enviesados pela forma de registro, as estimativas de desempenho e os indicadores agregados (como déficits projetados) exibem variabilidade adicional e podem ser de certa forma sistematicamente otimistas em cenários com “suficiência” apenas aparente. A literatura sobre simulação estocástica apresenta que, mesmo com muitas replicações, a incerteza nos insumos permanece um determinante central da confiabilidade dos resultados (CORLU et al., 2020).

Outro ponto a ser observado é o choque exógeno associado à pandemia de 2020, com normalização da situação ao longo do ano de 2021. O período apresentou patamares constantes e/ou quedas na quantidade de cursados por restrição de oferta, não necessariamente por redução da necessidade de capacitação a bordo dos navios. Em séries curtas, choques desse tipo configuram quebras estruturais, que podem distorcer a inferência e a extrapolação se interpretados como uma dinâmica permanente; logo, parte do comportamento observado nesse intervalo reflete condições atípicas de oferta (STOCK, 1994).

Em síntese, o estudo de caso ficou sujeito a (i) limitação de mensuração dos cursado (pessoas que possuem curso vs pessoas que possuem o curso e exercem funções que precisam desse curso), (ii) choque de quebra estrutural no início da amostra e (iii) incerteza de entrada pela curta extensão histórica. Tais fatores não invalidam os resultados, mas delimitam o nível de confiança apropriado: as recomendações configuram



uma orientação quantitativa superior ao processo atual, devendo ser interpretadas com cautela e complementadas por julgamento especializado e revisão contínua à luz de novos dados e de eventos operacionais. Essa prática de combinar evidência quantitativa com conhecimento de domínio e atualização iterativa, é consistente com diretrizes consolidadas em previsão e tomada de decisão (HYNDMAN e ATHANASOPOULOS, 2021; PETROPOULOS, 2022; ZELLNER et al., 2021).

Por fim, convém ressaltar que os ganhos observados no Modelo 1 devem ser vistos levando-se em consideração essas informações: onde a quantidade de pessoas que possuem o curso pode não ser a mesma que exerce a função que usa essa qualificação, ocorrendo uma carência não observada que a modelagem, por construção dos dados, não captaria plenamente. Assim, as conclusões desta pesquisa permanecem válidas no escopo do que é mensurado, e reforçam a importância de documentação transparente das hipóteses de dados e da verificação e validação contínuas do processo analítico (SARGENT, 2020).

## 6 CONCLUSÕES

### 6.1 SÍNTESE DOS OBJETIVO ATINGIDOS

De modo geral, assumindo que os dados coletados representam adequadamente o fenômeno observado, pode-se afirmar que os objetivos da pesquisa foram atingidos. O objetivo geral — propor e avaliar modelos quantitativos de apoio à distribuição das vagas em cursos — foi atendido por meio do desenvolvimento e aplicação de cinco modelos de otimização capazes de apoiar decisões sob restrições de recursos e metas de atingimento de índices. Dentre eles, dois modelos são determinísticos e operam com a “fotografia” das informações no momento da distribuição, enquanto três são estocásticos e incorporam a dinâmica dos dados históricos por meio de simulações de cenários, permitindo antecipar possíveis necessidades antes da distribuição anual de vagas.

Quanto aos objetivos específicos, foram elaboradas e aplicadas formulações que equilibram o atingimento de índices e o uso eficiente de recursos; foi incorporada a opinião de especialista para refletir conhecimento tácito do processo; e foram integradas medidas de risco para lidar com incertezas, conferindo maior robustez às recomendações. As soluções foram comparadas à prática vigente, possibilitando avaliar ganhos de eficiência tanto no atendimento das metas quanto na contenção de sobras e déficits. Por fim, a análise crítica das práticas atualmente realizadas permitiu identificar lacunas e oportunidades de melhoria no processo, tanto de distribuição quanto de solicitação de vagas em cursos, oferecendo um avanço metodológico e prático para o problema estudado.

Como evidência quantitativa sintética dos resultados, considerando o conjunto avaliado de 54 cursos (18 cursos em cada um dos 3 navios), observou-se melhora no atingimento do índice ideal após a otimização, com destaque para os modelos determinísticos. O Modelo 1 atingiu 51 cursos no índice ideal (94,4%), restando 3 cursos abaixo do ideal, enquanto o Modelo 2 atingiu 49 cursos no índice ideal (90,7%), restando 5 abaixo do ideal; no baseline (Real), 46 cursos atingiam o ideal (85,2%), com 8 abaixo do ideal. Ressalta-se que, em todos os modelos avaliados, não foram observados casos de cursos abaixo do índice mínimo, o que reforça a aderência das formulações às metas de qualificação.

As metodologias propostas abrem espaço para refinamentos futuros, sobretudo com a integração de métodos quantitativos adicionais ao que já é realizado atualmente,

quando dados mais extensos e consistentes estiverem disponíveis, sem prejuízo da validade das evidências apresentadas neste estudo.

## 6.2 CONTRIBUIÇÕES PARA A MARINHA

Os modelos propostos constituem um bom instrumento de apoio à gestão de vagas em cursos, com potencial de aumentar a eficiência na distribuição de vagas e reduzir o uso de recursos, frente à restrição orçamentária que tem sido um enfrentamento constante na instituição. Ao estruturar o problema matematicamente, a decisão deixa de depender exclusivamente de critérios subjetivos e passa a ser auditável e reproduzível, favorecendo a expansão para outros cursos, navios e Esquadrões.

Adicionalmente, as simulações estocásticas baseadas em dados históricos indicam a viabilidade do uso na fase de planejamento (solicitação de vagas para o ano seguinte), ao antecipar cenários de possíveis demandas de capacitação e permitir incorporar níveis de aversão ao risco. Em conjunto, esses resultados contribuem para o aumento da precisão e da governança do processo de capacitação e se alinham às diretrizes institucionais, em especial a OBNAV-11 (Aprimorar a gestão de pessoas), a AEN-Pessoal 2 (Aprimorar a capacitação de pessoal da MB) e a PEM-2040, reforçando o vínculo entre capacitação e prontidão operacional.

## 6.3 SUGESTÕES PARA TRABALHOS FUTUROS

Com a realização desta pesquisa, vislumbrou-se a possibilidade de realização de trabalhos futuros como:

- a) Identificar de fatores que influenciam a movimentação não planejada de pessoal a bordo e quantificar seus impactos na cobertura de cursos;
- b) Avaliar métodos de previsão mais avançados, incluindo técnicas de Inteligência Artificial para séries de contagem, comparando-os com as estratégias atuais utilizadas neste trabalho;
- c) Aplicar metodologias de consenso, como o método Delphi, para a definição de buffers, envolvendo um número maior de cursos e navios; e
- d) Integrar o controle de cursos aos sistemas de informação da Marinha utilizados para gestão de pessoal, de forma que, além de registrar entrada e saída de militares, passem também a relacionar cada militar aos cursos que possui, permitindo atualização contínua dos índices de capacitação.

## REFERÊNCIAS

- ACERBI, Carlo; TASCHE, Dirk. **On the coherence of expected shortfall**. Journal of Banking & Finance, v. 26, n. 7, p. 1487–1503, jul. 2002. DOI: 10.1016/S0378-4266(02)00283-2. DOI: [https://doi.org/10.1016/S0378-4266\(02\)00283-2](https://doi.org/10.1016/S0378-4266(02)00283-2)
- ACKERMANN, Andres E. F.; SELLITTO, Miguel A. **Métodos de previsão de demanda: uma revisão da literatura**. Innovar, Bogotá, v. 32, n. 85, p. 83–99, 2022. DOI: <https://doi.org/10.15446/innovar.v32n85.100979>
- AL-OSH, M. A.; ALZAID, A. A. **First-order integer-valued autoregressive (INAR(1)) process**. Journal of Time Series Analysis, v. 8, n. 3, p. 261–275, 1987. DOI: <https://doi.org/10.1111/j.1467-9892.1987.tb00438.x>
- ARTZNER, Philippe; DELBAEN, Freddy; EBER, Jean-Marc; HEATH, David. **Coherent measures of risk**. Mathematical Finance, v. 9, n. 3, p. 203–228, 1999. DOI: 10.1111/1467-9965.00068. DOI: <https://doi.org/10.1111/1467-9965.00068>
- BELFIORE, P. P.; FÁVERO, L. P. L. **Pesquisa operacional para cursos de administração**. Rio de Janeiro: Elsevier, 2012.
- BRASIL. Marinha do Brasil. **Amazônia Azul**. [S.l.]: Marinha do Brasil, [s.d.]. Disponível em: [https://www.mar.mil.br/hotsites/amazonia\\_azul/](https://www.mar.mil.br/hotsites/amazonia_azul/). Acesso em: 10 jul. 2025.
- BRASIL. MARINHA DO BRASIL. **Plano Estratégico da Marinha (PEM 2040)**. Marinha do Brasil, 2020. Disponível em: <https://www.marinha.mil.br/publicacoes/pem2040>. Acesso em: 6 set. 2025.
- CORLU, Canan G.; AKCAY, Alp; XIE, Wei. **Stochastic simulation under input uncertainty: A Review**. Operations Research Perspectives, v. 7, 2020, 100162. DOI: <https://doi.org/10.1016/j.orp.2020.100162>

DAVIS, Richard A.; FOKIANOS, Konstantinos; HOLAN, Scott H.; JOE, Harry; LIVSEY, James; LUND, Robert; PIPIRAS, Vladas; RAVISHANKER, Nalini. **Count Time Series: A Methodological Review**. Journal of the American Statistical Association, v. 116, n. 535, p. 1533–1547, 2021. DOI: <https://doi.org/10.1080/01621459.2021.1904957>.

ENDERS, Walter. **Applied Econometric Time Series**. 4. ed. Hoboken: John Wiley & Sons, 2015.

FERIGATO, Evandro; ROSINI, Alessandro Marco. **Strategic Planning in People Management: A Case Study**. Journal of Sustainable Competitive Intelligence, v. 11, 2021, e0384. DOI: <https://doi.org/10.24883/IberoamericanIC.v11i.384>

FOKIANOS, Konstantinos. **Count time series models**. In: RAO, Tata Subba; RAO, Suhasini Subba; RAO, C. R. (Orgs.). Time Series Analysis: Methods and Applications. Amsterdam: Elsevier (Handbook of Statistics, v. 30), 2012. p. 315–347. DOI: <https://doi.org/10.1016/B978-0-444-53858-1.00012-0>

GERHARDT, Tatiana Engel; SILVEIRA, Denise Tolfo (org.). **Métodos de pesquisa**. 1. ed. Porto Alegre: Editora da UFRGS, 2009.

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 6. ed. São Paulo: Atlas, 2017.

GNEITING, Tilmann; KATZFUSS, Matthias. **Probabilistic forecasting**. Annual Review of Statistics and Its Application, v. 1, p. 125–151, 2014. DOI: <https://doi.org/10.1146/annurev-statistics-062713-085831>

HASSANI, Hossein; ROYER-CARENZI, Manuela; MARVIAN MASHHAD, Leila; YARMOHAMMADI, Masoud; YEGANEHI, Mohammad Reza. **Exploring the Depths of the Autocorrelation Function: Its Departure from Normality**. Information, v. 15, n. 8, 449, 2024. DOI: <https://doi.org/10.3390/info15080449>

HAUSKEN, Kjell. **Fifty Years of Operations Research in Defense**. European Journal of Operational Research, v. 318, n. 2, p. 355–368, 2024. DOI: <https://doi.org/10.1016/j.ejor.2023.12.023>

HOLDEN, R. **Engineering the total ship: A system perspective on warships**. Naval engineers journal, v. 117, n. 3, p. 63-77, 2005. DOI: <https://doi.org/10.1111/j.1559-3584.2005.tb00362.x>

HOPKIN, Cameron R.; HOYLE, Rick H.; GOTTFREDSON, Nisha C. **Maximizing the Yield of Small Samples in Prevention Research: A Review of General Strategies and Best Practices**. Prevention Science, v. 16, n. 7, p. 950–955, 2015. DOI: <https://doi.org/10.1007/s11121-014-0542-7>

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: Principles and Practice**. 3. ed. Melbourne: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>. Acesso em: 6 out. 2025.

HYNDMAN, Rob J.; KOSTENKO, Andrey. **Minimum sample size requirements for seasonal forecasting models**. Foresight: The International Journal of Applied Forecasting, n. 6, p. 12–15, Spring 2007. Disponível em: [Minimum sample size requirements for seasonal forecasting models – Rob J Hyndman](#) Acesso em: 6 out. 2025.

IMORO, Rafiatu; AWAAB, John Ayuekanbey; AKAMISE, Kennedy. **Modeling students enrolment in Statistics Department using time series analysis**. International Journal of Applied Science and Research, v. 3, n. 2, p. 113–128, mar./abr. 2020. Disponível em: <https://www.ijasr.org/paper/IJASR0042176.pdf> Acesso em: 5 out. 2025.

KWIATKOWSKI, Denis; PHILLIPS, Peter C. B.; SCHMIDT, Peter; SHIN, Yongcheol. **Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?** Journal of Econometrics, v. 54, n. 1–3, p. 159–178, 1992. DOI: [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)

LINSMEIER, Thomas J.; PEARSON, Neil D. **Risk Measurement: An Introduction to Value at Risk**. Urbana-Champaign: University of Illinois at Urbana-Champaign, 1996. Working paper. Disponível em: [https://www.researchgate.net/publication/23744167\\_Risk\\_Measurement\\_An\\_Introduction\\_to\\_Value\\_at\\_Risk](https://www.researchgate.net/publication/23744167_Risk_Measurement_An_Introduction_to_Value_at_Risk). Acesso em: 16 out. 2025.

MCKENZIE, E. **Some simple models for discrete variate time series**. Water Resources Bulletin, v. 21, n. 4, p. 645–650, 1985. DOI: <https://doi.org/10.1111/j.1752-1688.1985.tb05379.x>

ODION, P. O.; MUSA, M. N.; ZACHARIAH, B. **Resource Allocation Optimization using Mixed Integer Programming within Mission Essential Tasks of Military Training in the Nigerian Defence Academy**. International Journal of Computing Intelligence and Security Research (IJCISR), v. 2, n. 1, p. 36–46, 2023. Disponível em: [https://www.researchgate.net/publication/374373699\\_RESOURCE\\_ALLOCATION\\_OPTIMIZATION\\_USING\\_MIXED\\_INTEGER\\_PROGRAMMING\\_WITHIN\\_MISSION\\_ESSENTIAL\\_TASKS\\_OF\\_MILITARY\\_TRAINING\\_IN\\_THE\\_NIGERIAN\\_DEFENCE\\_ACADEMY](https://www.researchgate.net/publication/374373699_RESOURCE_ALLOCATION_OPTIMIZATION_USING_MIXED_INTEGER_PROGRAMMING_WITHIN_MISSION_ESSENTIAL_TASKS_OF_MILITARY_TRAINING_IN_THE_NIGERIAN_DEFENCE_ACADEMY) Acesso em: 12 out. 2025.

PERRON, Pierre. **The Great Crash, the Oil Price Shock, and the Unit Root Hypothesis**. Econometrica, v. 57, n. 6, p. 1361–1401, nov. 1989. DOI: 10.2307/1913712. Disponível em: <https://www.jstor.org/stable/1913712> Acesso em: 8 set. 2025.

PETROPOULOS, Fotios; KOURENTZES, Nikolaos; NIKOLOPOULOS, Konstantinos; SIEMSEN, Enno. **Judgmental selection of forecasting models**. Journal of Operations Management, v. 60, p. 34-46, 2018. DOI: <https://doi.org/10.1016/j.jom.2018.05.005>

PETROPOULOS, Fotios; APILETTI, Daniele; ASSIMAKOPOULOS, Vassilios; et al. **Forecasting: theory and practice**. International Journal of Forecasting, v. 38, n. 3, p. 705–871, 2022. DOI: <https://doi.org/10.1016/j.ijforecast.2021.11.001>

PINCHEIRA, Pablo M.; MEDEL, Carlos A. **Forecasting with a random walk.** Finance a úvěr – Czech Journal of Economics and Finance, v. 66, n. 6, p. 539–564, 2016. Disponível em: [\[PDF\] Forecasting with a Random Walk | Semantic Scholar](#) Acesso em: 5 out. 2025.

PINO, Manuel Emilio Milla; ORDONEZ, Freddi Roland Rodríguez; YSA, Ricardo Ángel Shimabuku; LLANOS, Diomer Marino Jara; CRUZ, Maria Marleni Torres; CALDERÓN, Billy Alexis Cayatopa. **Role of Expert in Validation of Information Collection Instruments for Business Purposes.** International Journal of Professional Business Review, Miami, v. 8, n. 8, p. 01–11, 2023. DOI: <https://doi.org/10.26668/businessreview/2023.v8i8.3122>

PUJARI, Shveni; VASUDEVA, Siddhant; KUDVA, Sidharth; MEHARIA, Sonika; GUPTA, Srishti; PATHAK, Sukriti. **Application of Operations Research Techniques in Human Resource Decision Making in Various Organizations.** International Journal of Advances in Engineering and Management (IJAEM), v. 3, n. 10, p. 491–497, out. 2021. Disponível em: [Application of Operations Research Techniques in Human Resource Decision Making in Various Organizations.pdf](#) Acesso em: 18 set. 2025.

ROCKAFELLAR, R. Tyrrell; URYASEV, Stanislav. **Optimization of Conditional Value-at-Risk.** [S.l.: s.n.], 1999. Working paper. Disponível em: <https://sites.math.washington.edu/~rtr/papers/rtr179-CVaR1.pdf>. Acesso em: 11 out. 2025.

ROLIM, Letícia. **Amazônia Azul: o tesouro marinho do Brasil que poucos conhecem.** *Portal Norte*, 1 abr. 2025. Disponível em: <https://portalnorte.com.br/noticias/amazonia/2025/04/01/amazonia-azul-o-tesouro-marinho-do-brasil-que-poucos-conhecem/>. Acesso em: 21 out. 2025.

Ryan, O.; Haslbeck, J. M. B.; Waldorp, L. J. **Non-Stationarity in Time-Series Analysis: Modeling Stochastic and Deterministic Trends.** *Multivariate Behavioral Research*, 60(3):556–588, 2025. DOI: <https://doi.org/10.1080/00273171.2024.2436413>



SÁNCHEZ-BEASKOETXEA, Javier; BASTERRETXEA-IRIBAR, Imanol; SOTÉS, Iranzu; MARURI MACHADO, María de las Mercedes. **Human error in marine accidents: Is the crew normally to blame?** Maritime Transport Research, v. 2, 2021, 100016. DOI: <https://doi.org/10.1016/j.martra.2021.100016>

SANTOS, T. et al. **Economia Azul: vetor para o desenvolvimento do Brasil.** RJ: Essential Idea, 2022.

SARGENT, Robert G. **Verification and validation of simulation models: An advanced tutorial.** In: Proceedings of the 2020 Winter Simulation Conference (WSC 2020), Orlando, FL, USA, 14–18 Dec. 2020. Piscataway, NJ: IEEE, 2020. p. 16–29. DOI: [10.1109/WSC48552.2020.9384052](https://doi.org/10.1109/WSC48552.2020.9384052)

SARYKALIN, Sergey; SERRAINO, Gaia; URYASEV, Stanislav. **Value-at-Risk vs. Conditional Value-at-Risk in Risk Management and Optimization.** In: CHEN, Zhi-Long; RAGHAVAN, S. (Orgs.). *Tutorials in Operations Research: State-of-the-Art Decision-Making Tools in the Information-Intensive Age.* Catonsville, MD: INFORMS, 2008. p. 270–294. DOI: <https://doi.org/10.1287/educ.1080.0052>

SENNA, Viviane de; SOUZA, Adriano Mendonça; UEDA, Renan Mitsuo. **Séries temporais e variáveis qualitativas: revisão sistemática de literatura.** Revista Produção Online, Florianópolis, v. 22, n. 1, p. 2349-2372, 2022. DOI: <https://doi.org/10.14488/1676-1901.v22i1.4575>

SOKOL, Andrej. **Fan charts 2.0: Flexible forecast distributions with expert judgement.** International Journal of Forecasting, v. 41, n. 3, p. 1148–1164, 2025. DOI: <https://doi.org/10.1016/j.ijforecast.2024.11.009>

STEUTEL, F. W.; VAN HARN, K. **Discrete analogues of self-decomposability and stability.** The Annals of Probability, v. 7, n. 5, p. 893–899, 1979. DOI: <https://doi.org/10.1214/aop/1176994950>

STOCK, James H. **Unit roots, structural breaks and trends.** In: ENGLE, Robert F.; McFADDEN, Daniel L. (eds.). *Handbook of Econometrics.* Amsterdam: Elsevier, 1994.

v. 4, p. 2739–2841. Disponível em:

<https://scholar.harvard.edu/files/stock/files/unitrootsstructuralbreaks.pdf> Acesso em: 15 out. 2025.

SZWED, Paul S. **Expert Judgment in Project Management: Narrowing the Theory-Practice Gap**. Newtown Square, PA: Project Management Institute, 2016. ISBN 978-1-62825-116-6. Disponível em: <https://www.pmi.org/-/media/pmi/documents/public/pdf/research/expert-judgement.pdf> Acesso em: 10 ago. 2025.

TOMAZ, Maria Aleksandra; TOMAZ, Antonio Alex Dayson. **A importância do treinamento e do desenvolvimento na gestão estratégica de pessoas na administração pública**. RECIMA21 – Revista Científica Multidisciplinar, v. 4, n. 10, e4104152, 13 out. 2023. DOI: <https://doi.org/10.47820/recima21.v4i10.4152>

WEISS, Christian H. **An introduction to discrete-valued time series**. Hoboken: John Wiley & Sons Ltd, 2018. DOI: <https://doi.org/10.1002/9781119097013>

YAMAVARAM, Anvitha; GILDA, Khushi; AGGARWAL, Megha; KOTAK, Om. **Applications of Operation Research in Military Operations Research – In Defense and Military Operations**. International Journal of Advances in Engineering and Management (IJAEM), v. 4, n. 10, p. 1299–1303, out. 2022. DOI: 10.35629/5252-041012991303. Disponível em: [Applications of Operation Research in Military Operations Research In Defense and Military Operations.pdf](#) Acesso em: 18 out. 2025.

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

ZELLNER, Maximilian; ABBAS, Ali E.; BUDESCU, David V.; GALSTYAN, Aram. **A survey of human judgement and quantitative forecasting methods**. *Royal Society Open Science*, v. 8, n. 2, e201187, 2021. DOI: <https://doi.org/10.1098/rsos.201187>

ZHU, Helin; LIU, Tianyi; ZHOU, Enlu. **Risk quantification in stochastic simulation under input uncertainty**. ACM Transactions on Modeling and Computer Simulation,

v. 30, n. 1, p. 1–24, 2020. DOI: 10.1145/3329117. DOI:  
<https://doi.org/10.1145/3329117>

## APÊNDICE A – ANÁLISE EXPLORATÓRIA DOS CURSOS

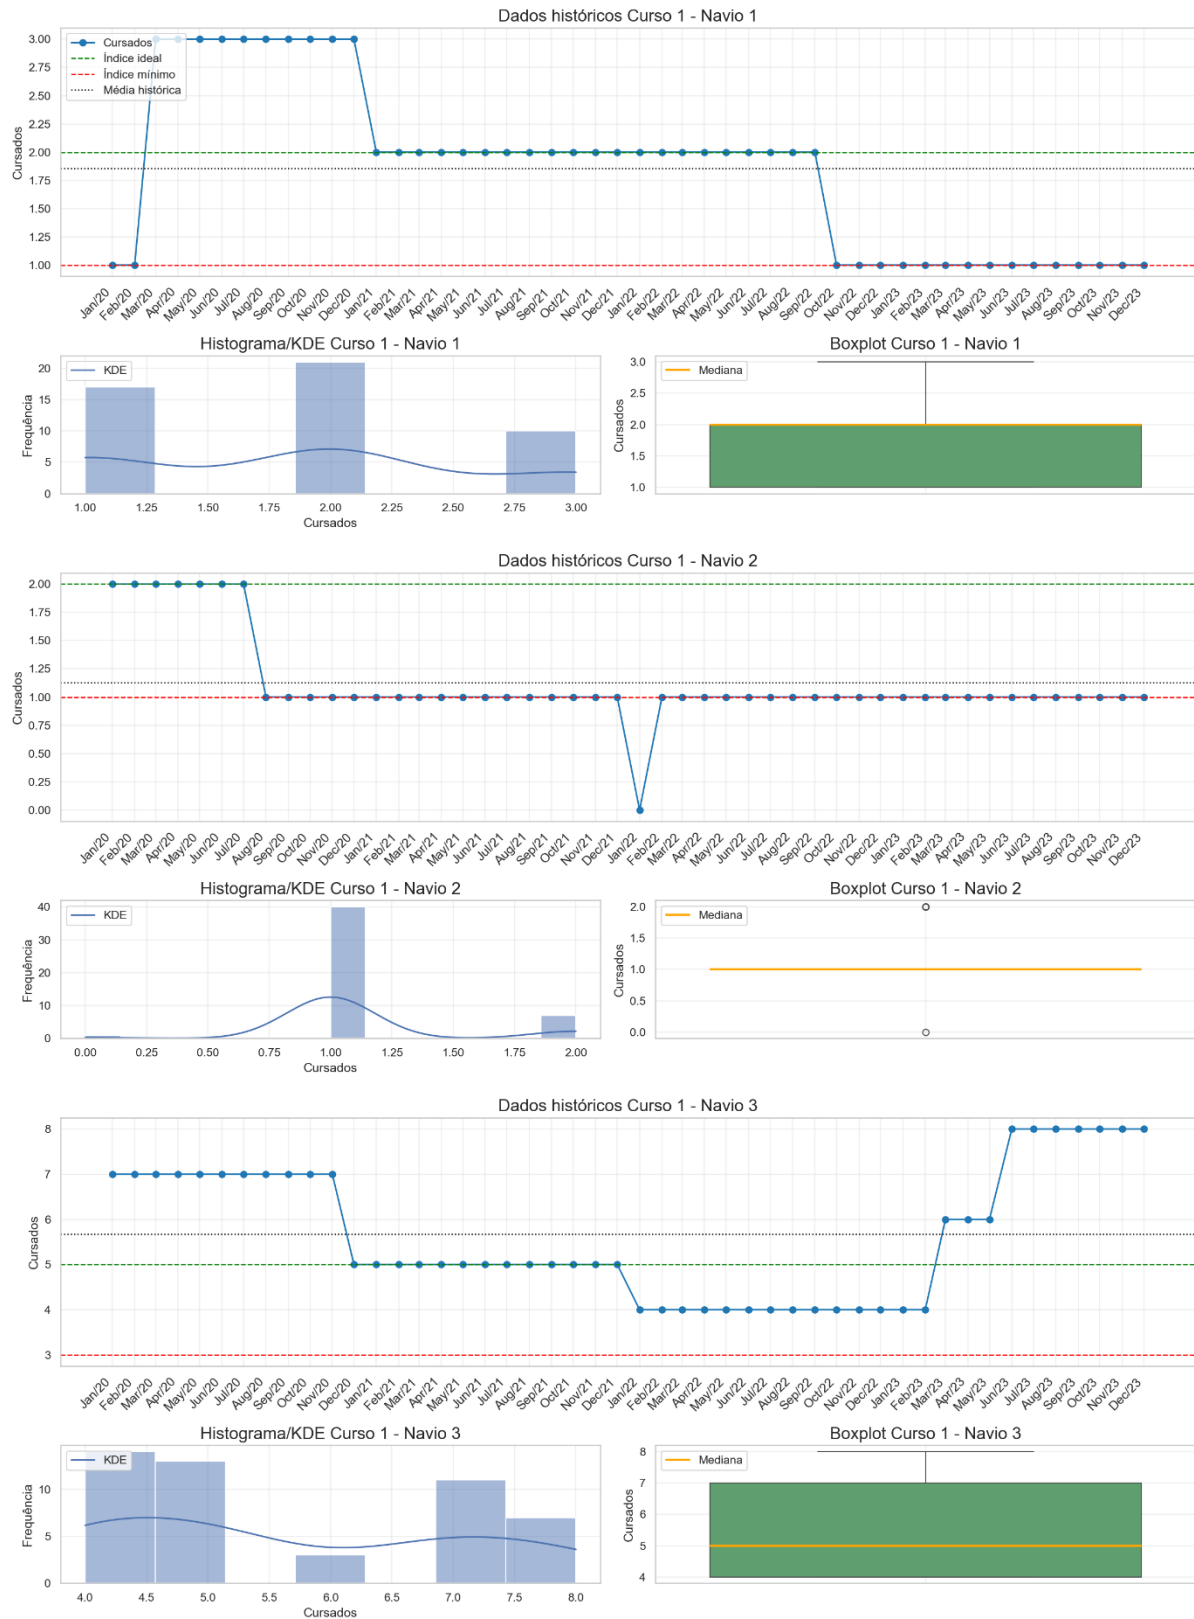


Figura 16 – Análise exploratória do Curso 1

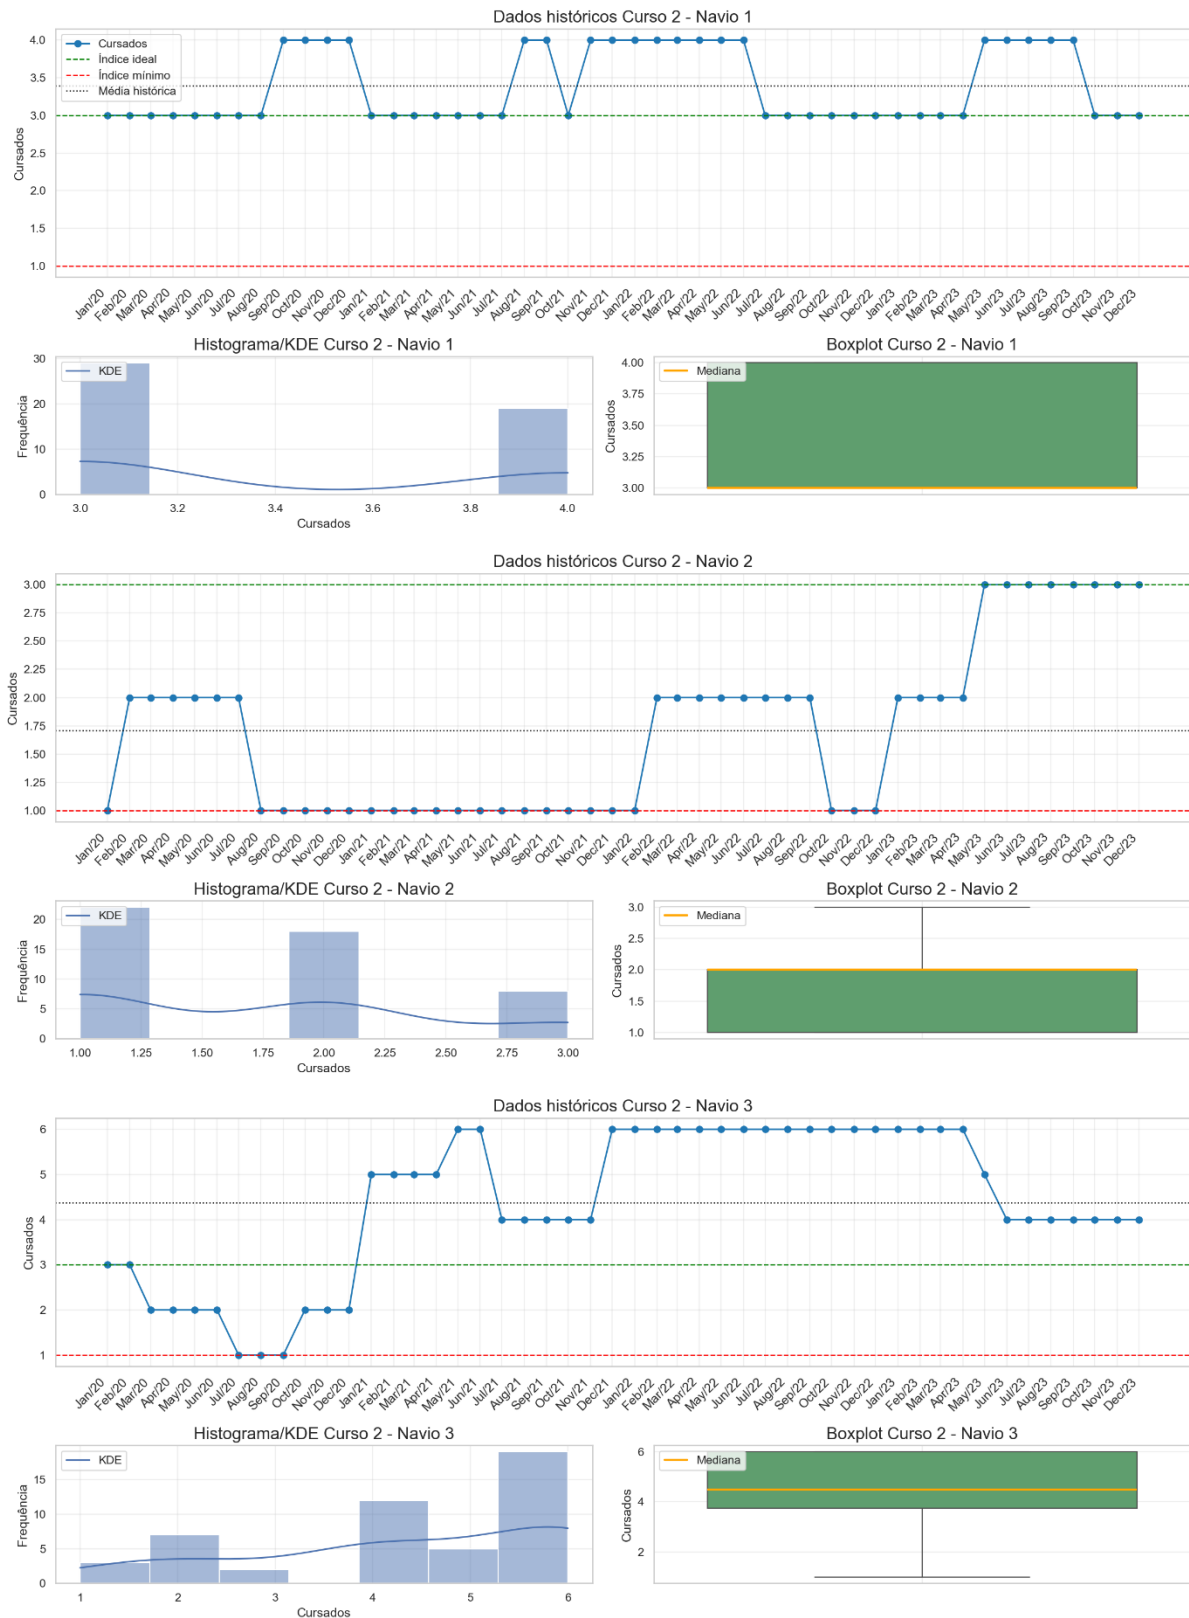


Figura 17 – Análise exploratória do Curso 2

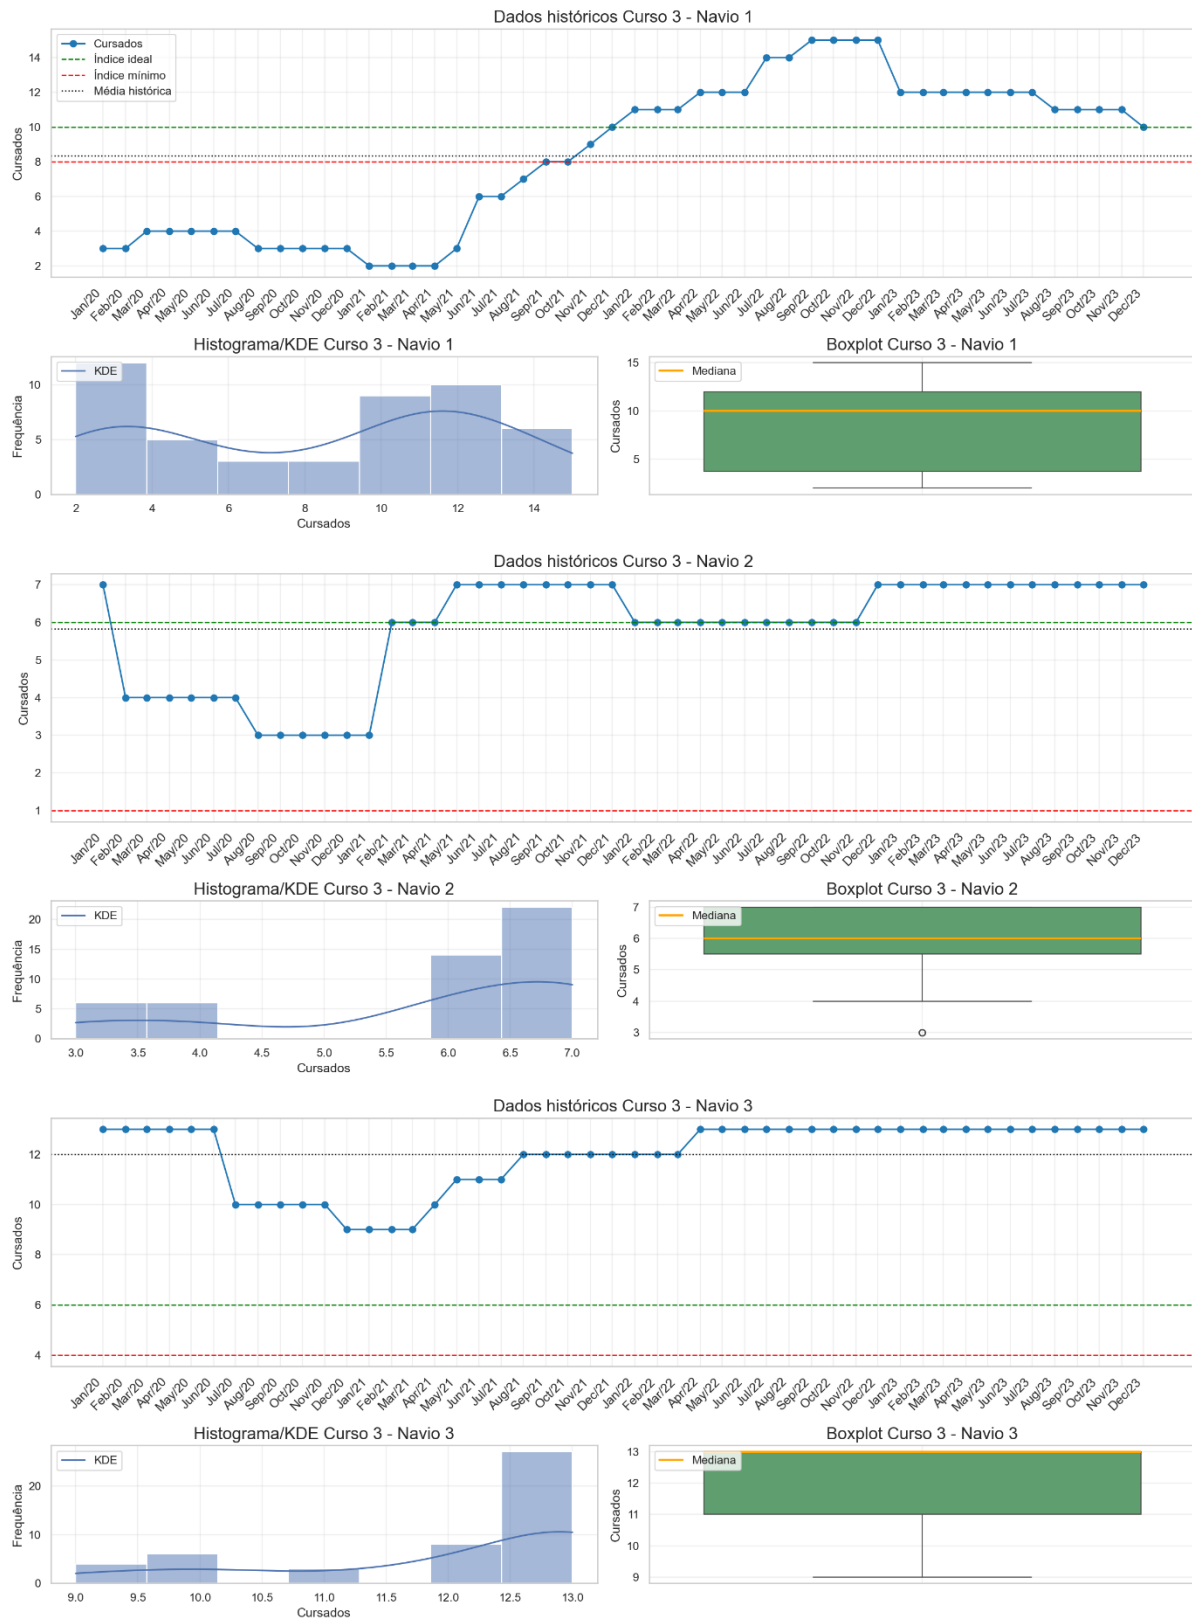


Figura 18 – Análise exploratória do Curso 3



Figura 19 – Análise exploratória do Curso 4<sup>1</sup>

<sup>1</sup> A tripulação dos navios é dividida em Oficiais e Praças. O Curso 4 é o único caso em que os índices variam de acordo com a quantidade de Praças a bordo, o ideal é 100% e o mínimo 90% desse pessoal.

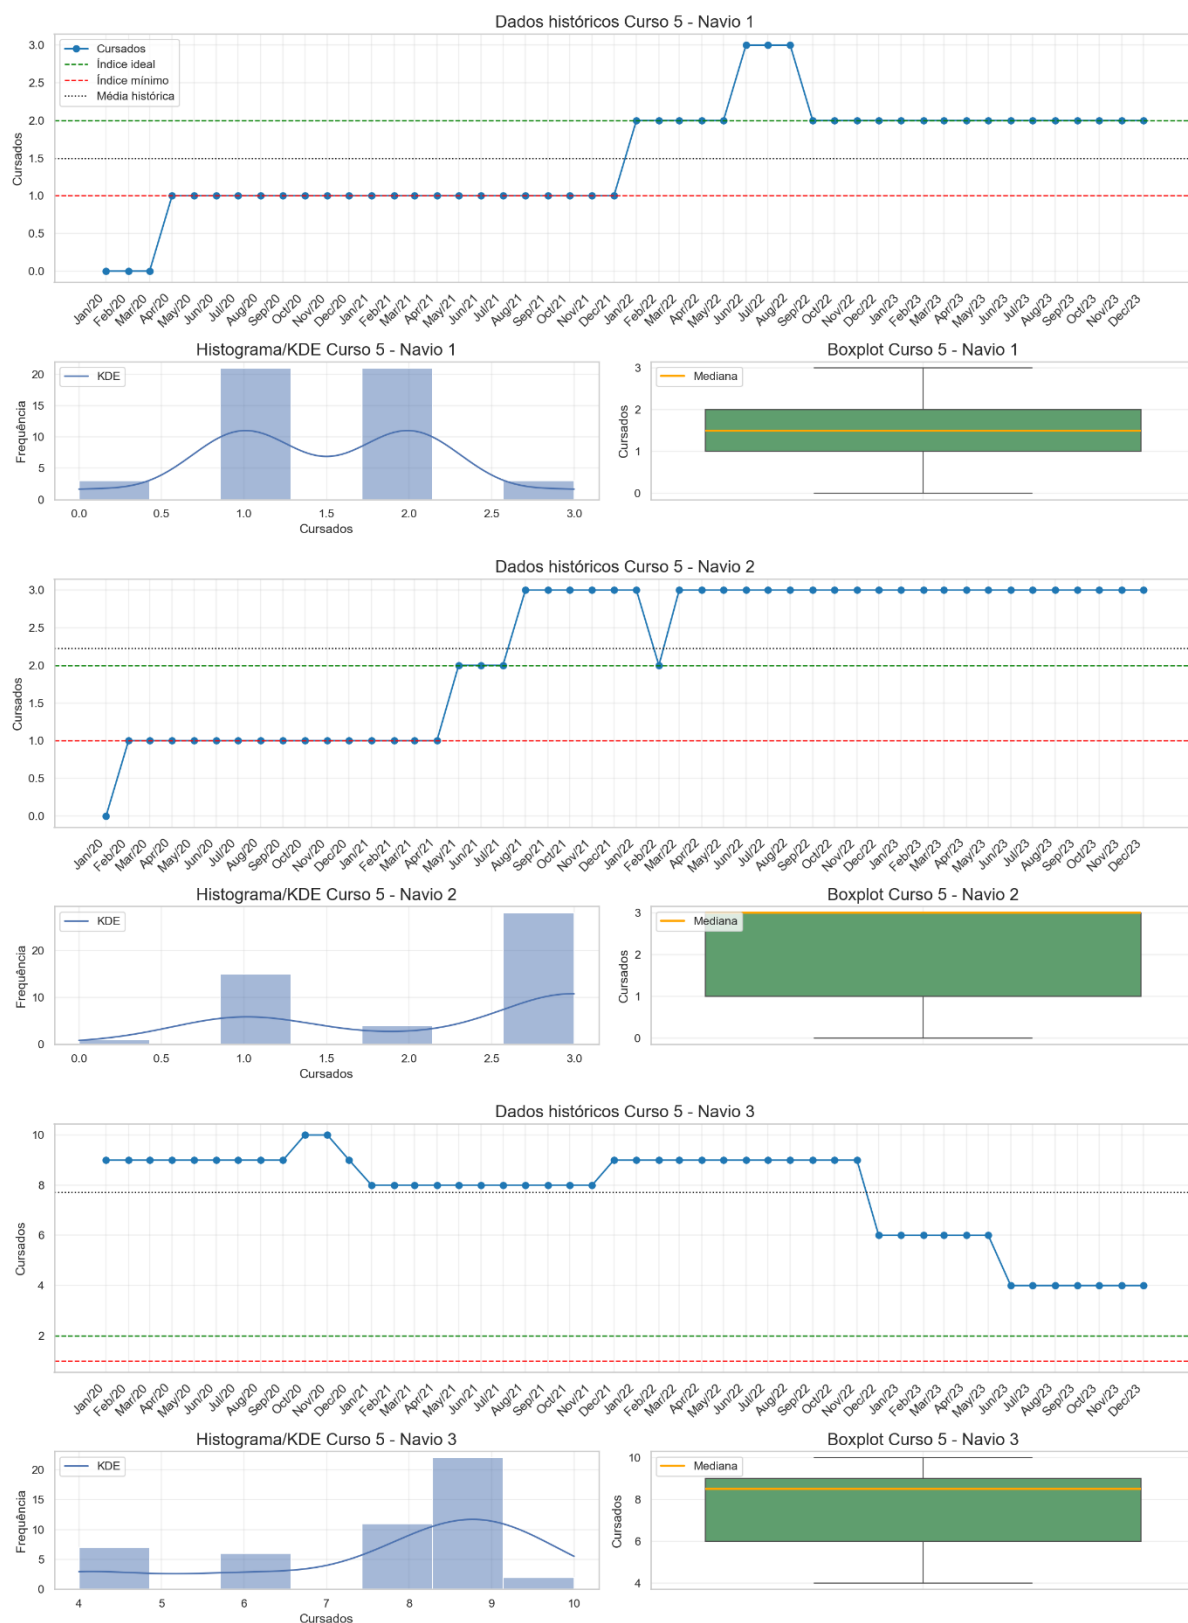


Figura 20 – Análise exploratória do Curso 5



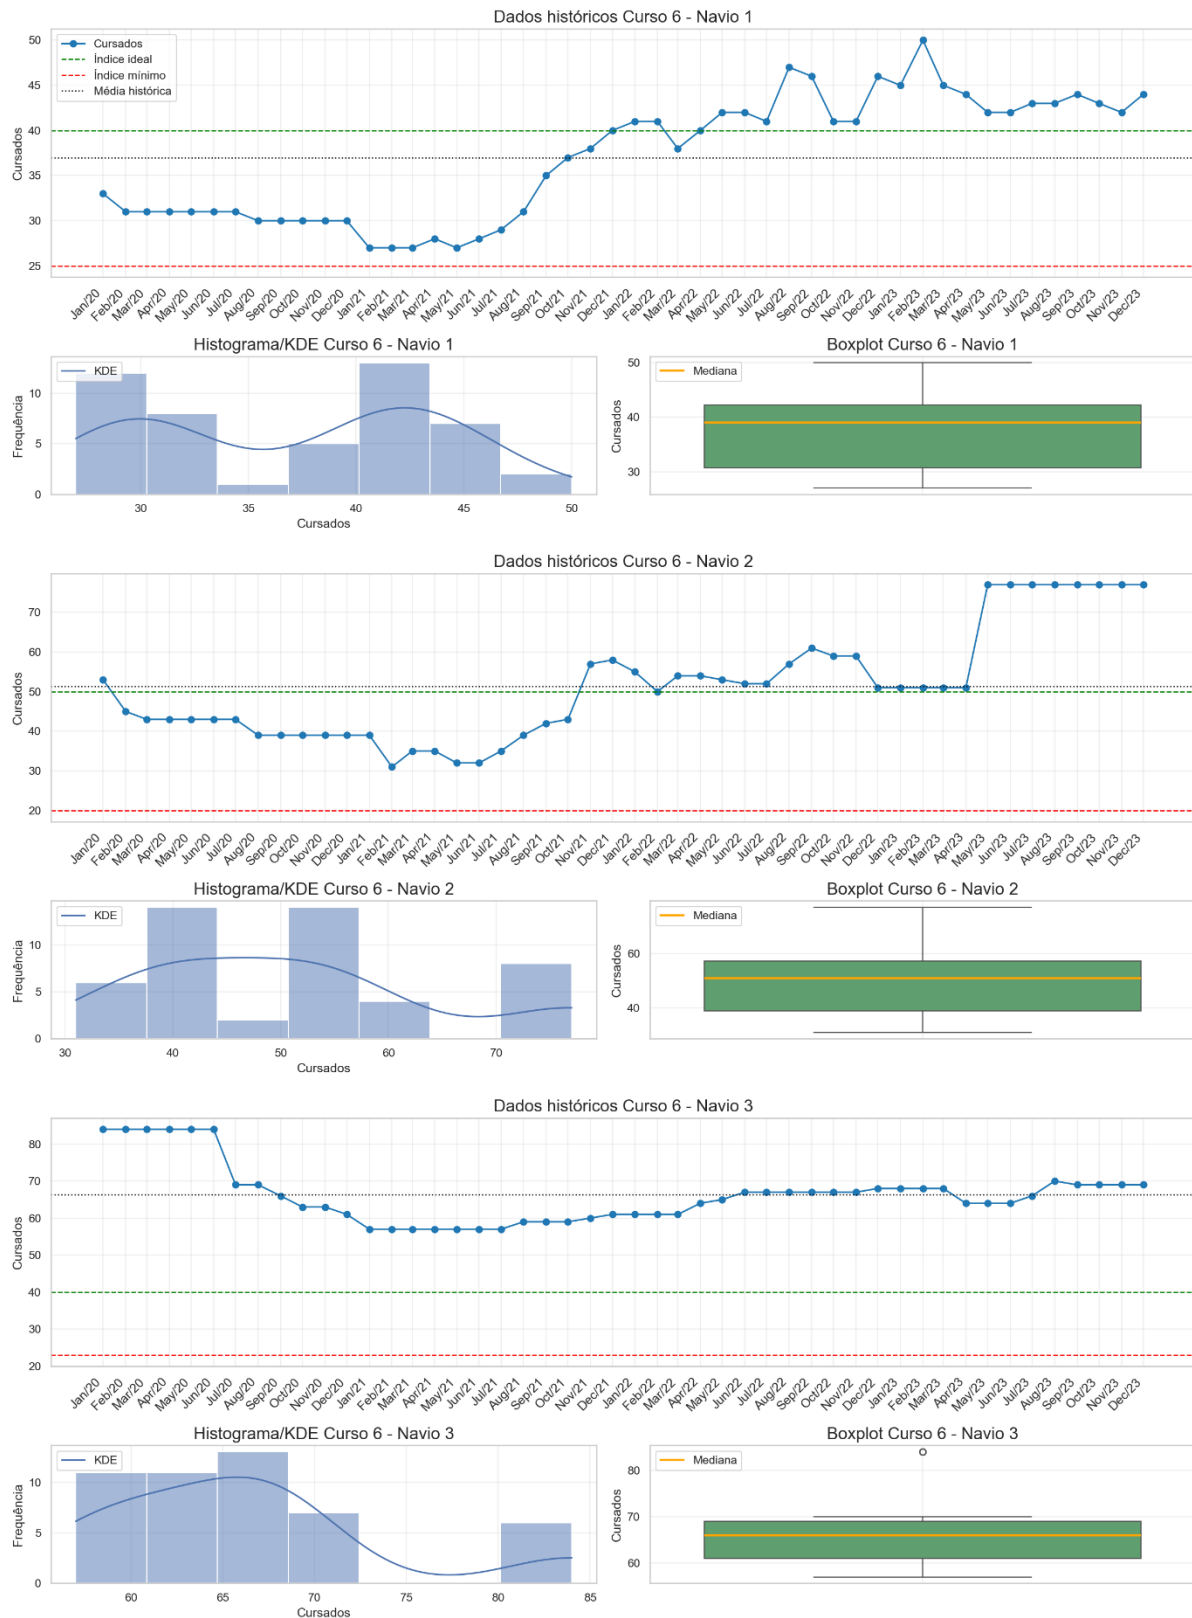


Figura 21 – Análise exploratória do Curso 6

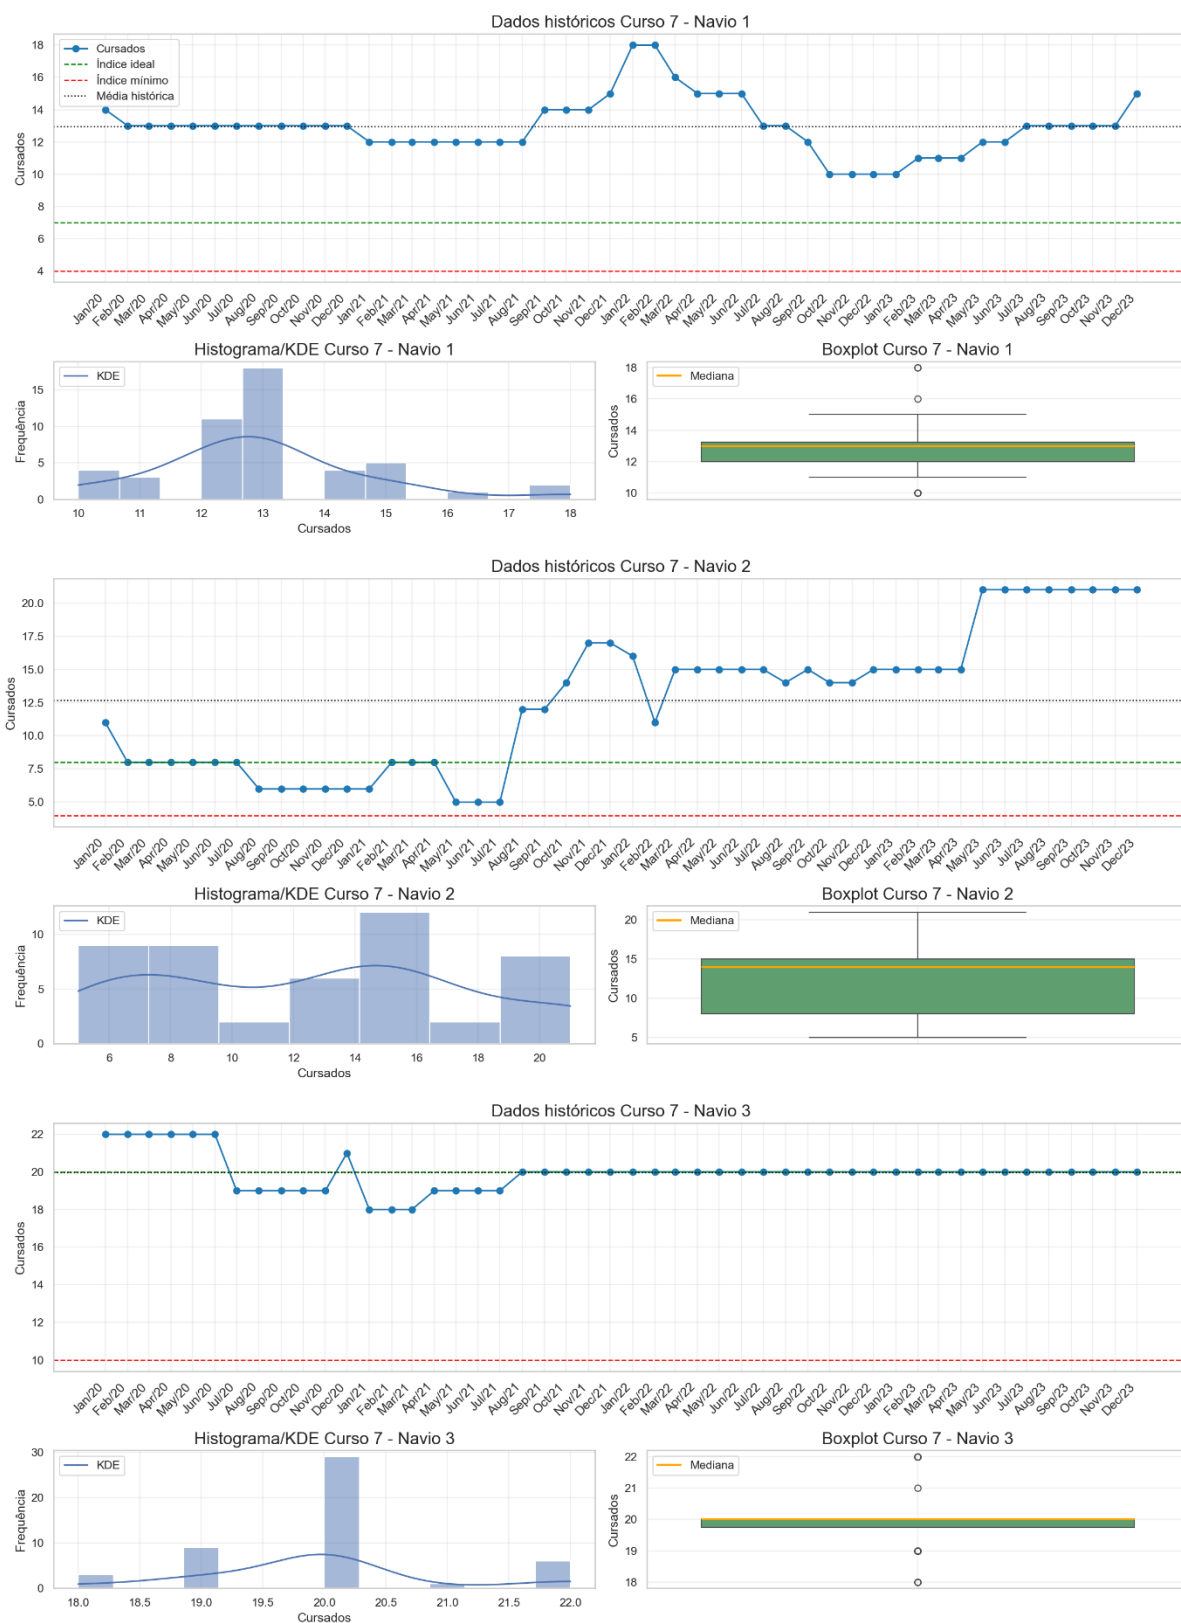


Figura 22 – Análise exploratória do Curso 7

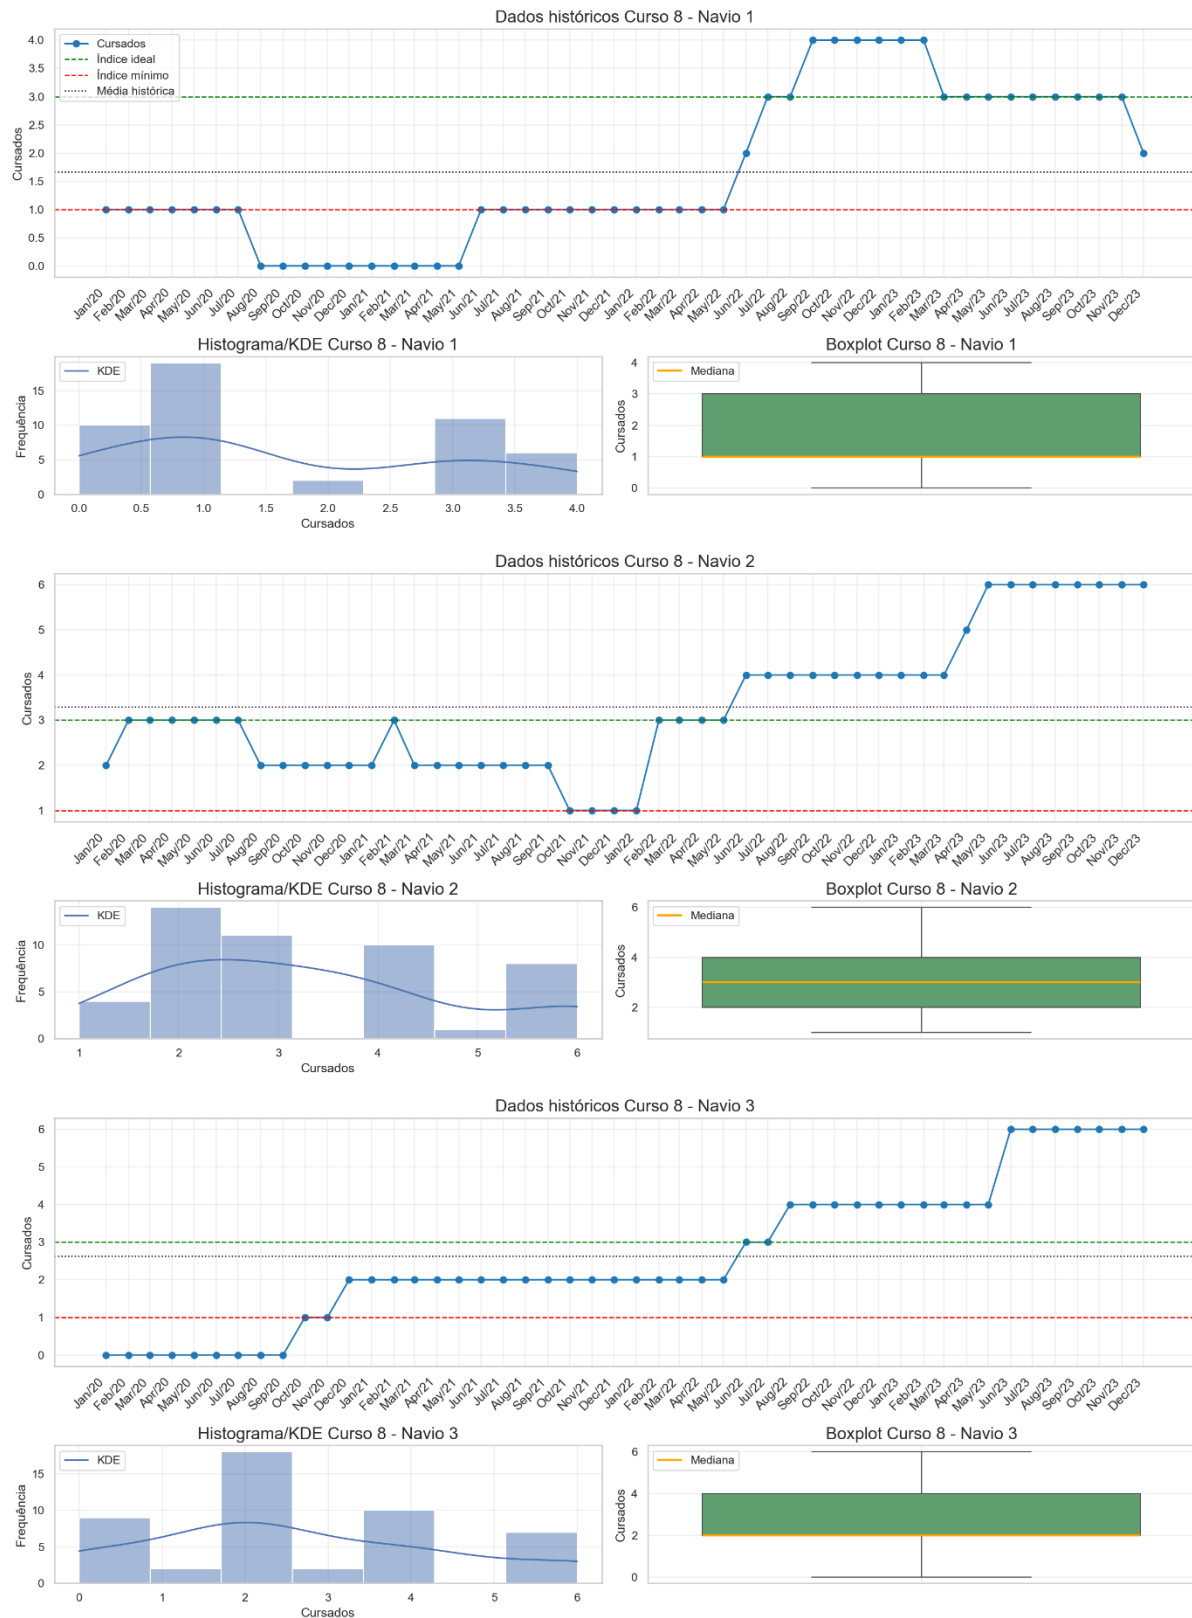


Figura 23 – Análise exploratória do Curso 8

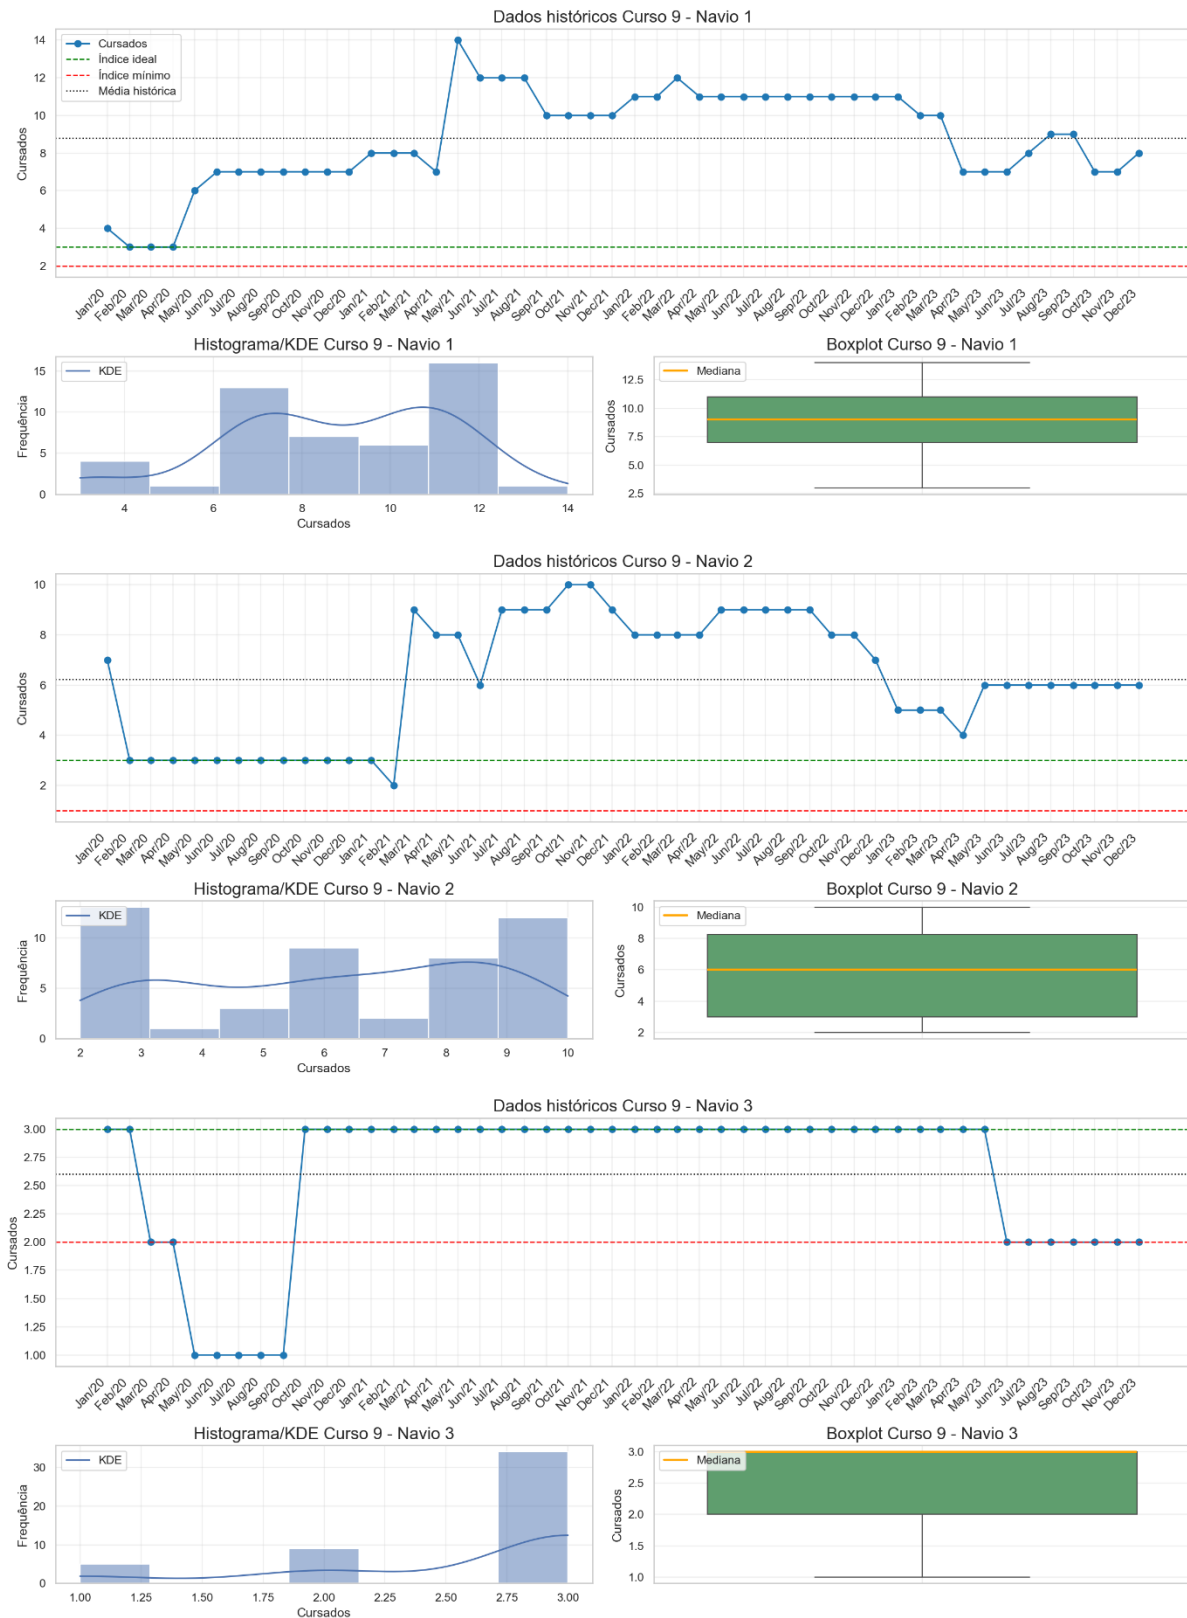


Figura 24 – Análise exploratória do Curso 9

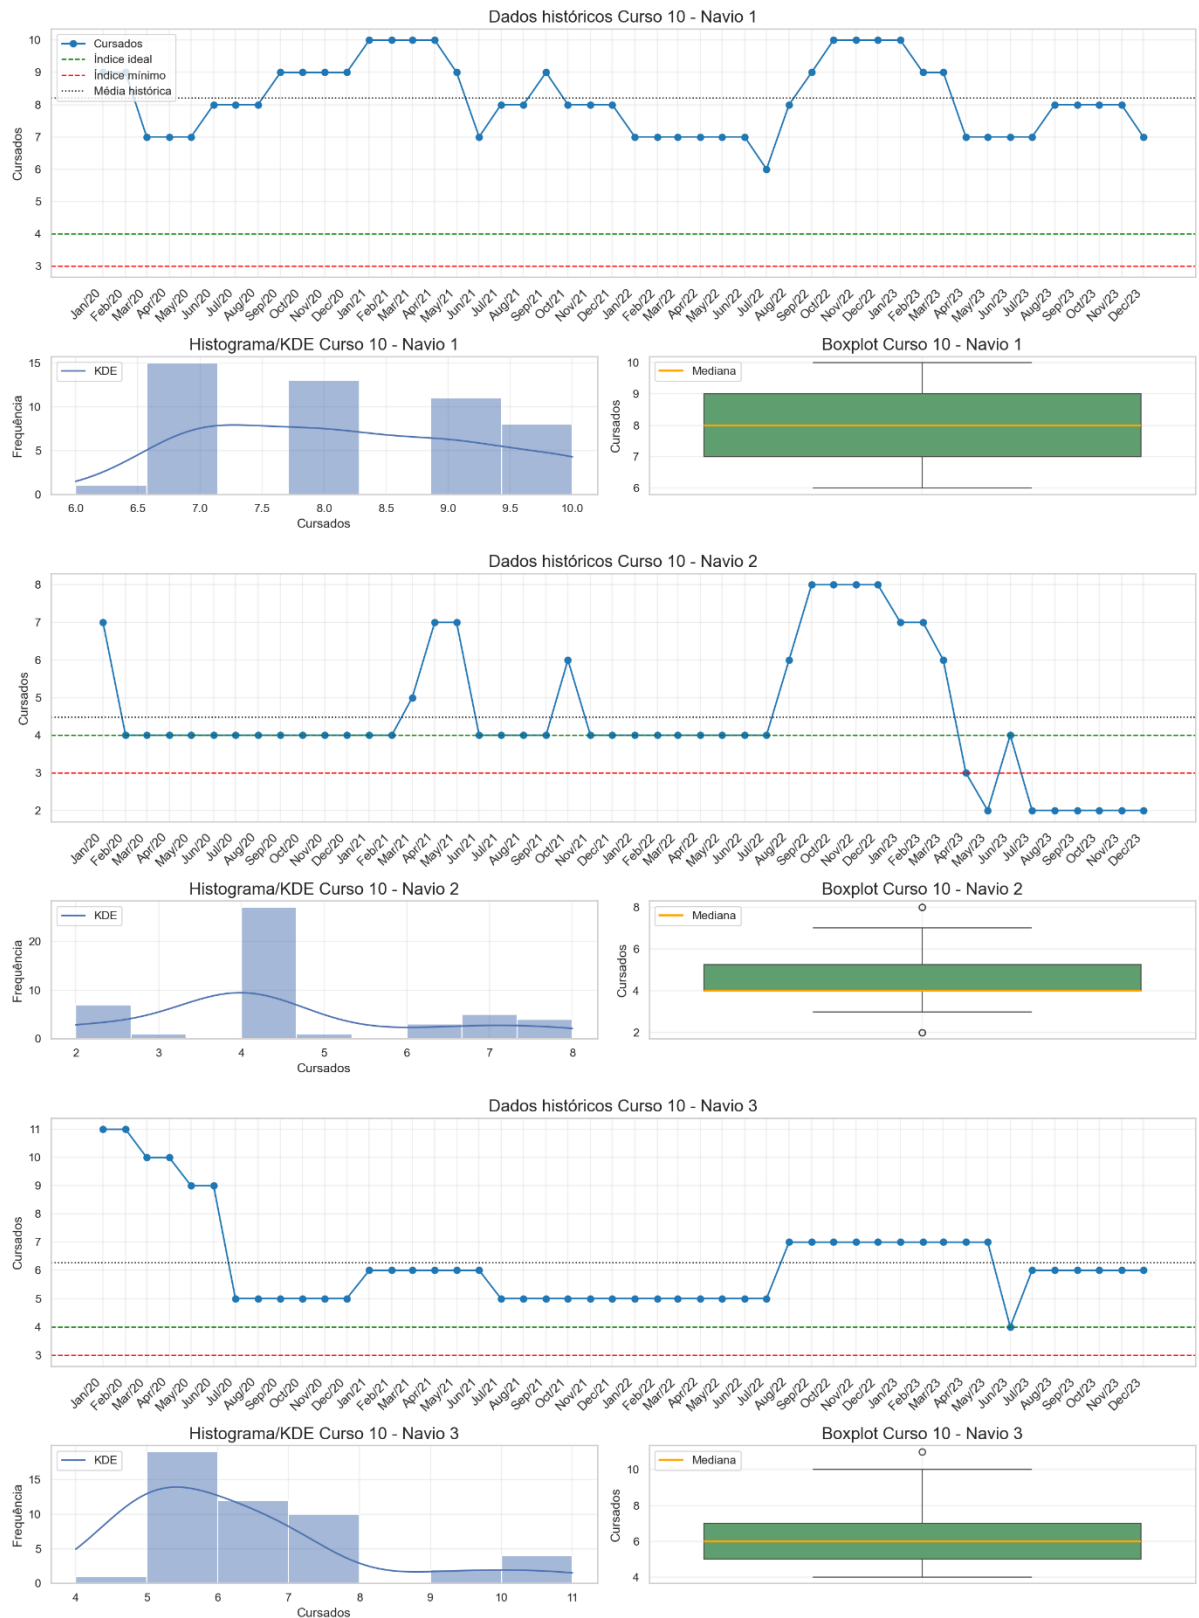


Figura 25 – Análise exploratória do Curso 10

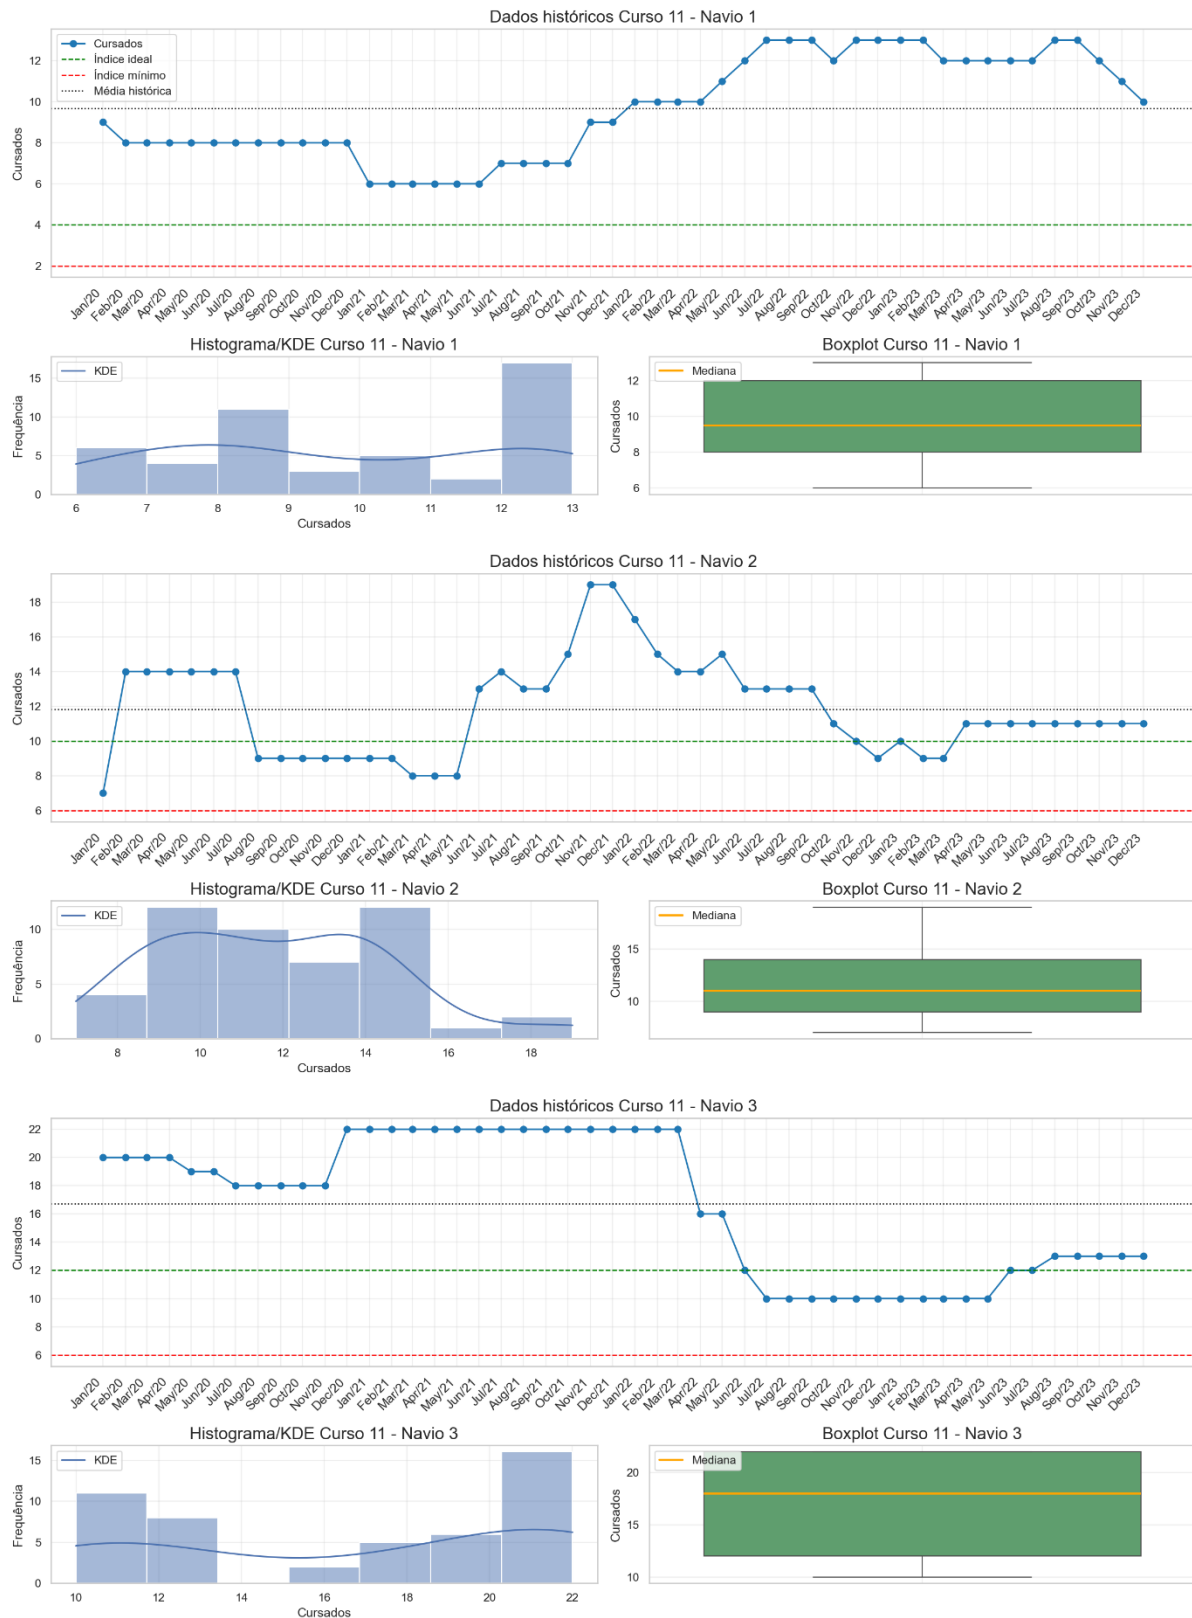


Figura 26 – Análise exploratória do Curso 11

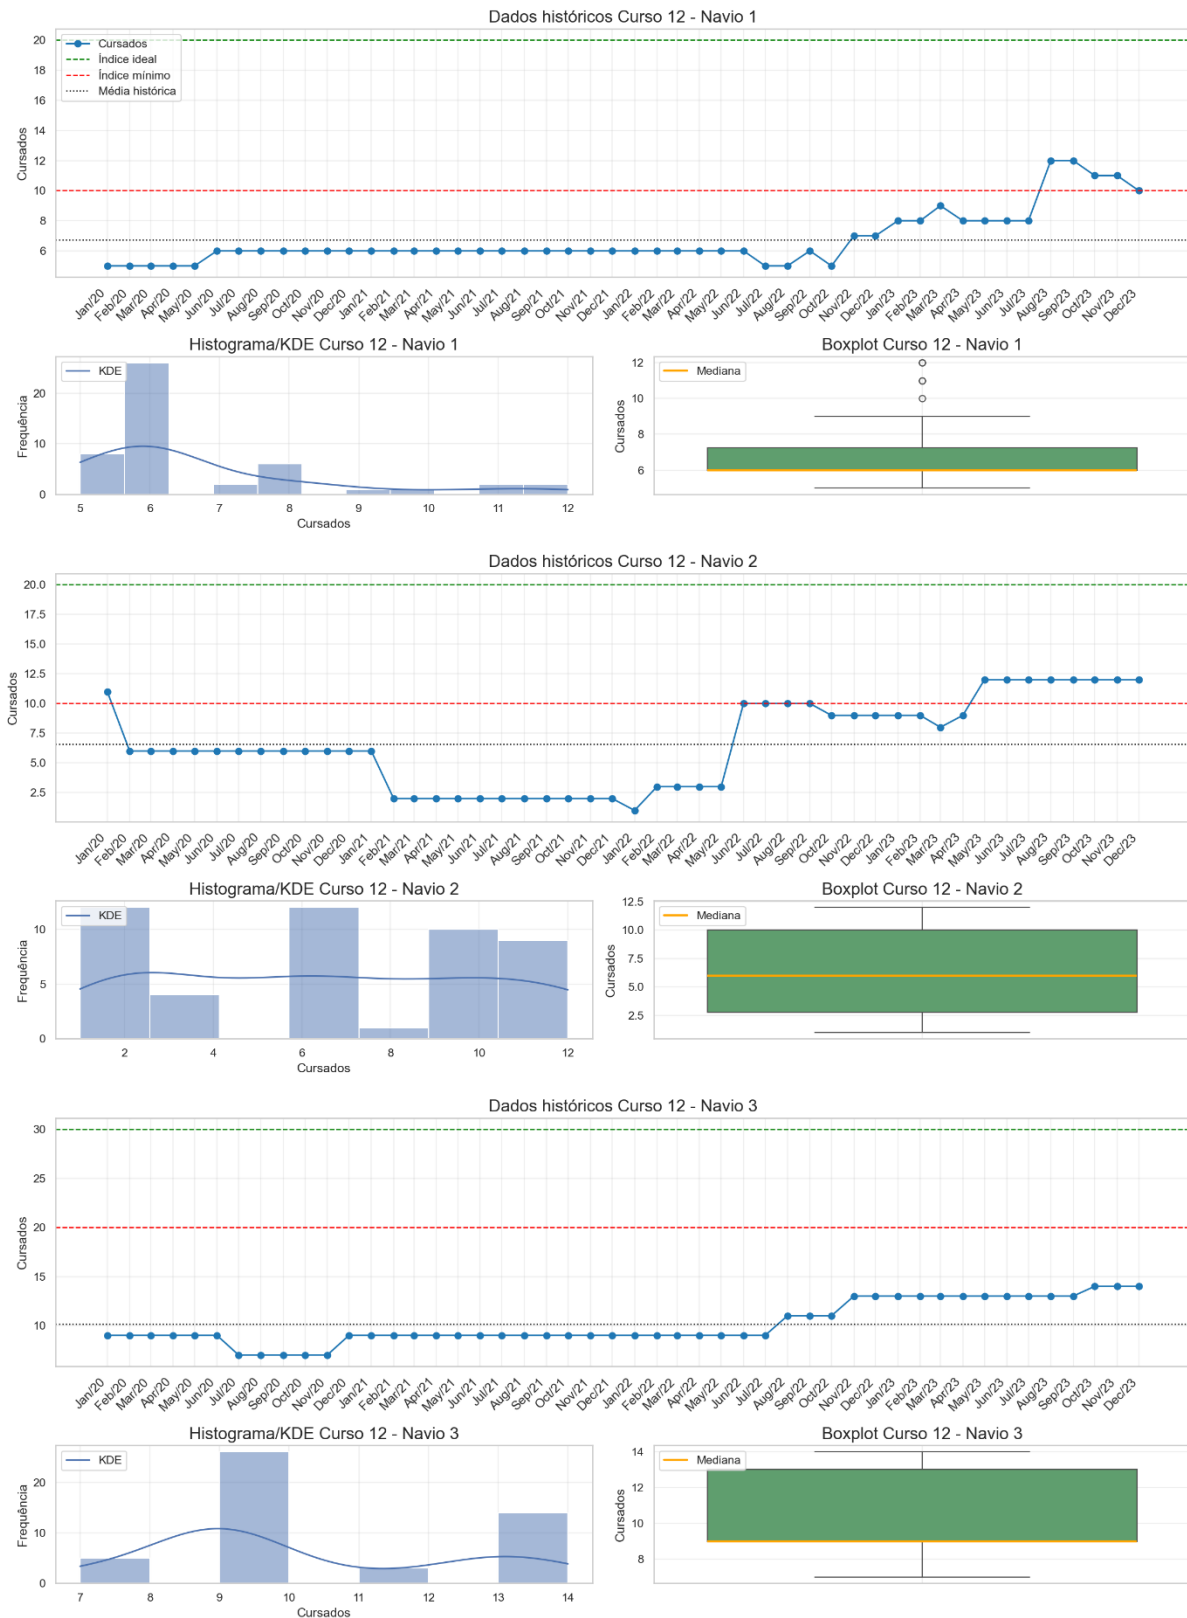


Figura 27 – Análise exploratória do Curso 12

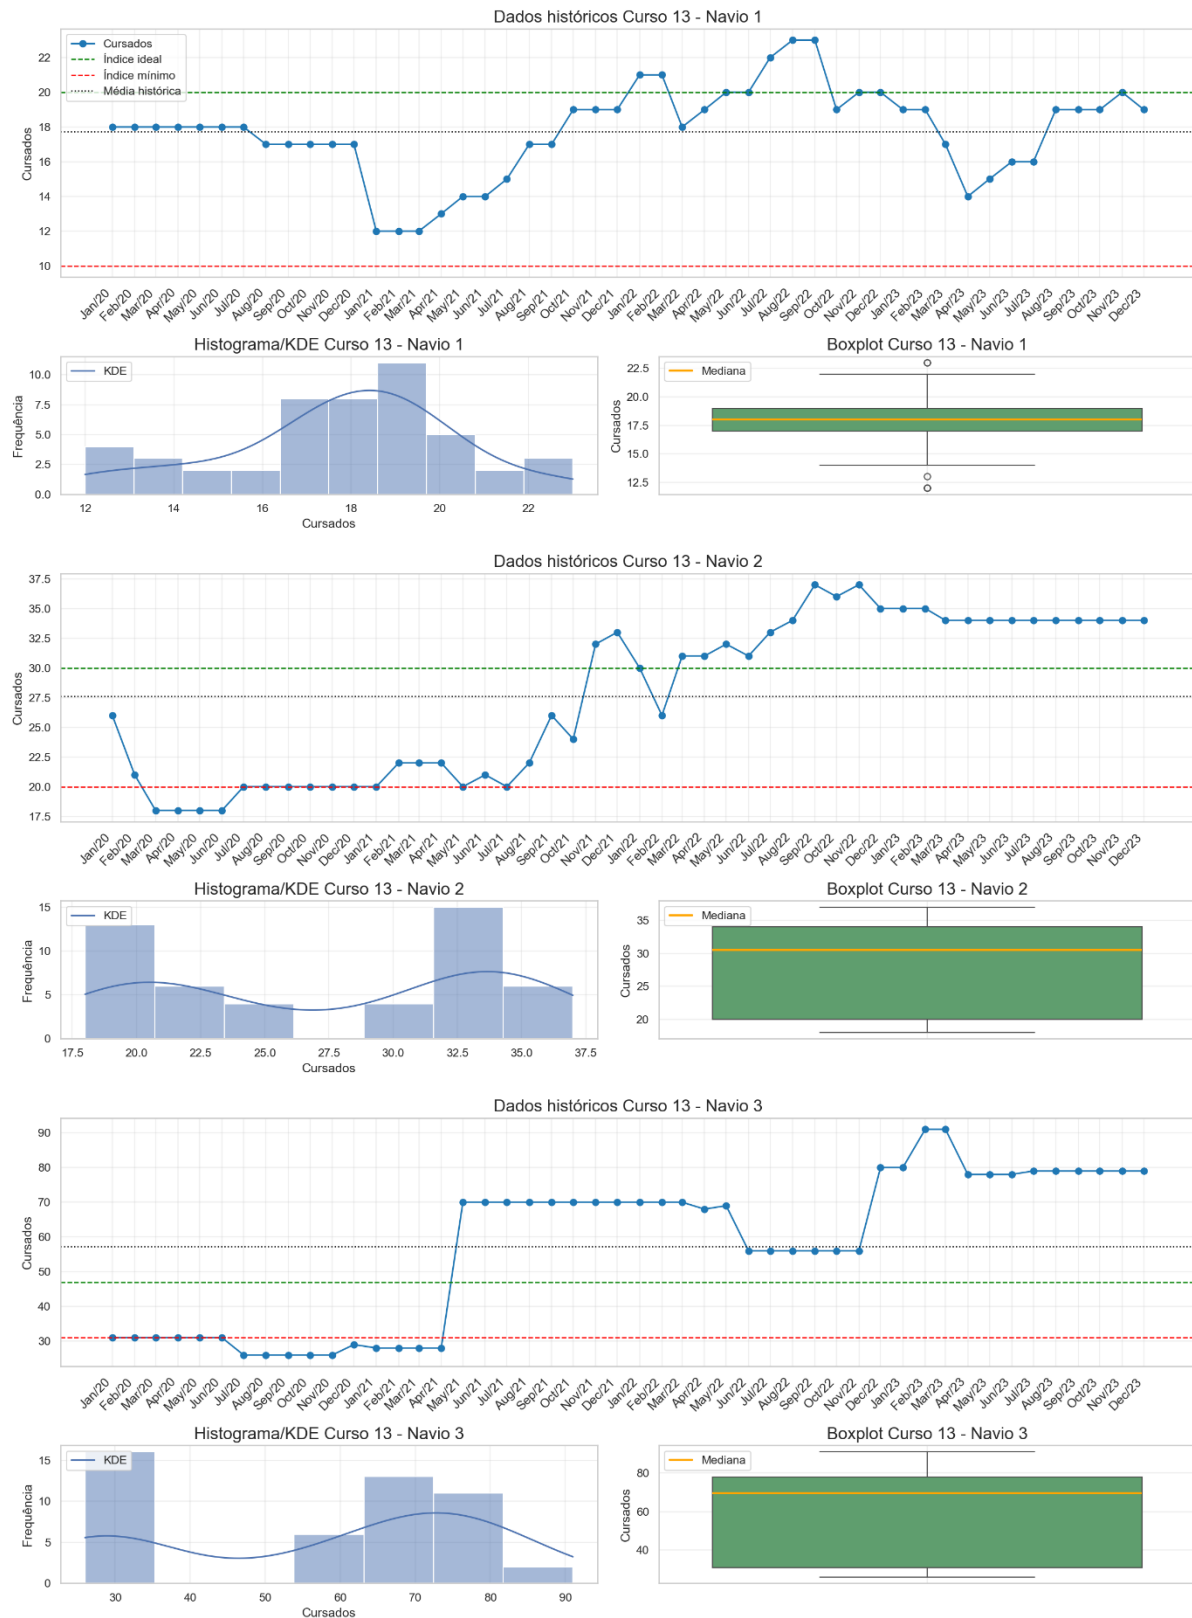


Figura 28 – Análise exploratória do Curso 13



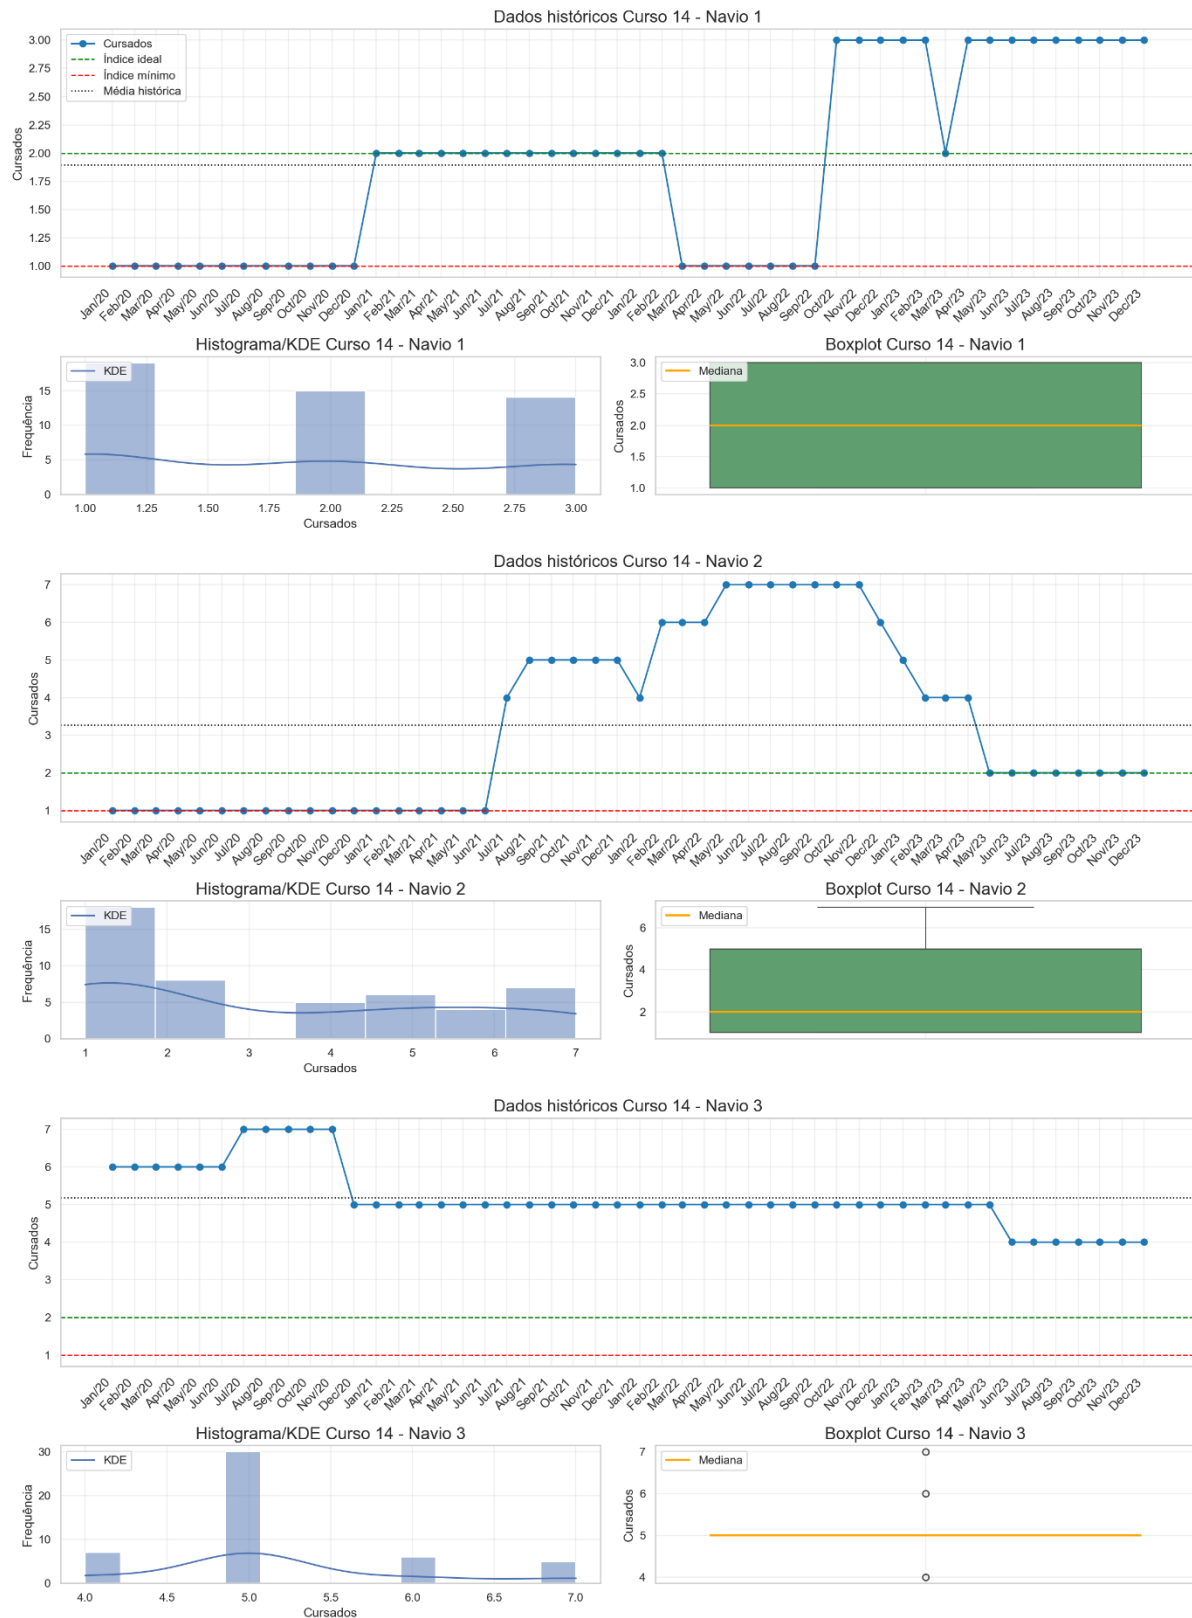


Figura 29 – Análise exploratória do Curso 14

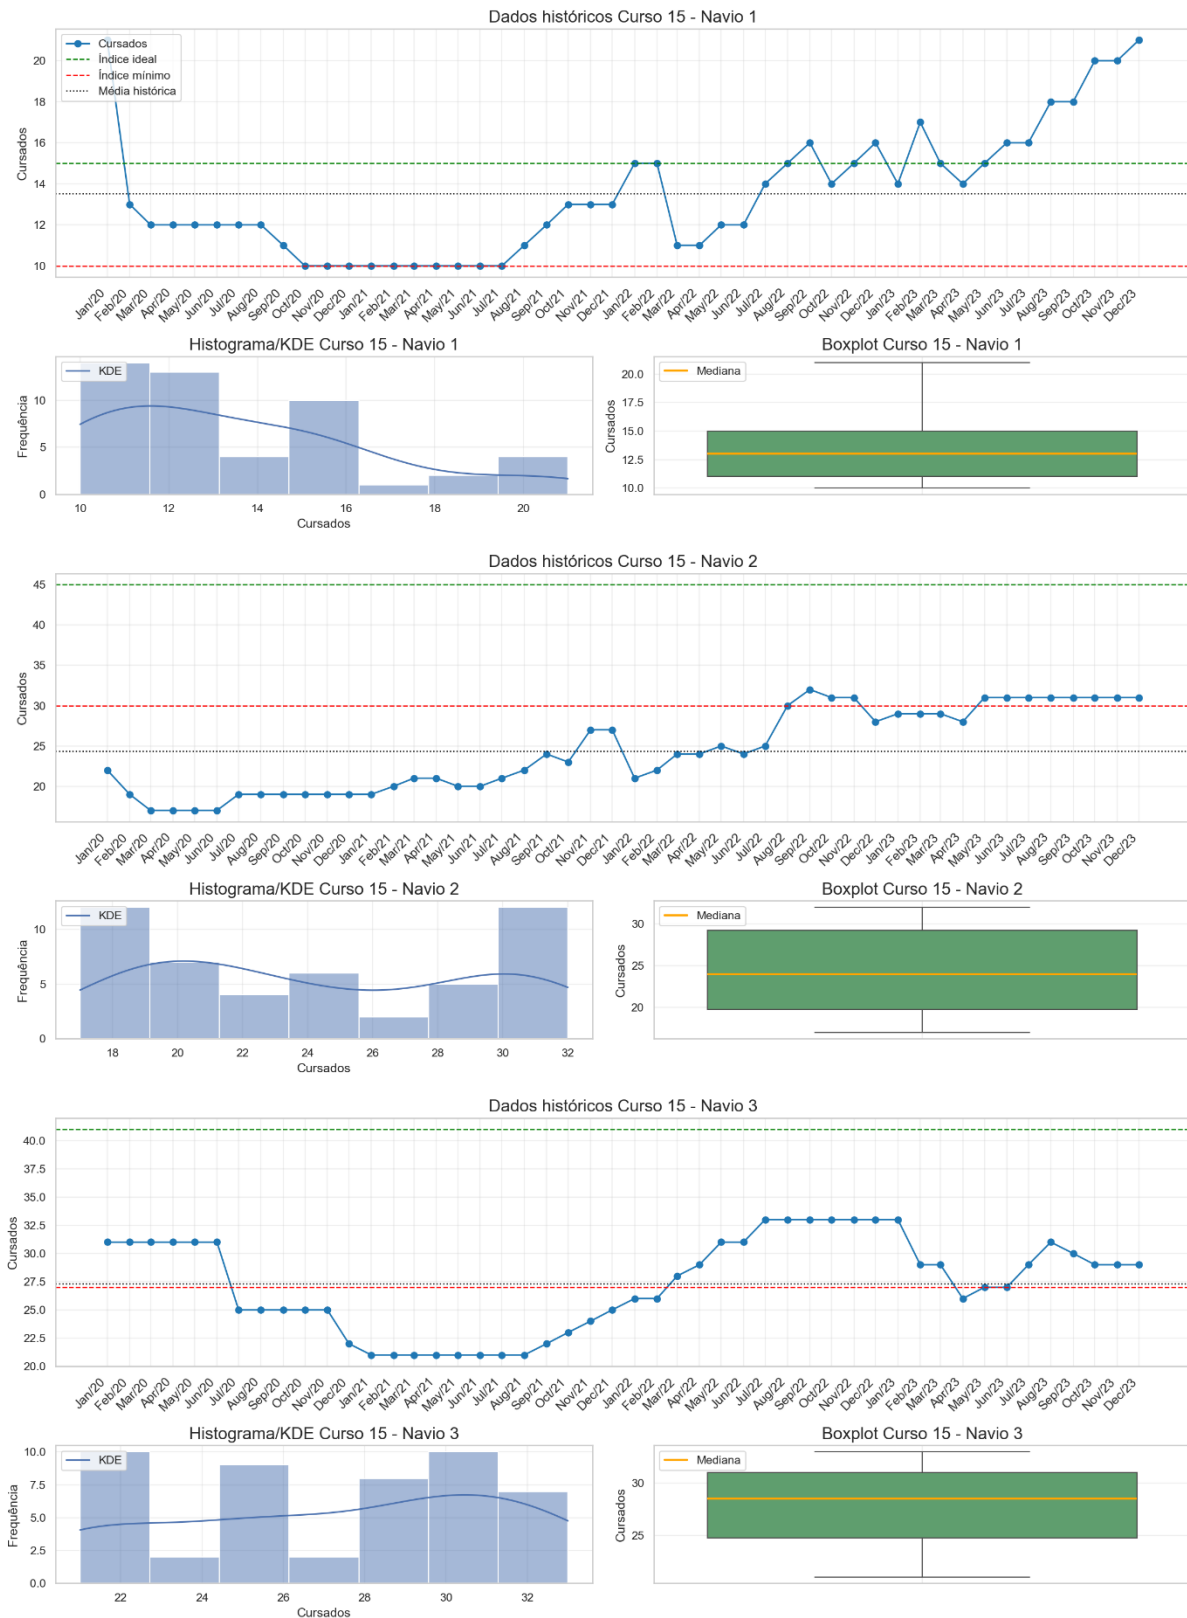


Figura 30 – Análise exploratória do Curso 15

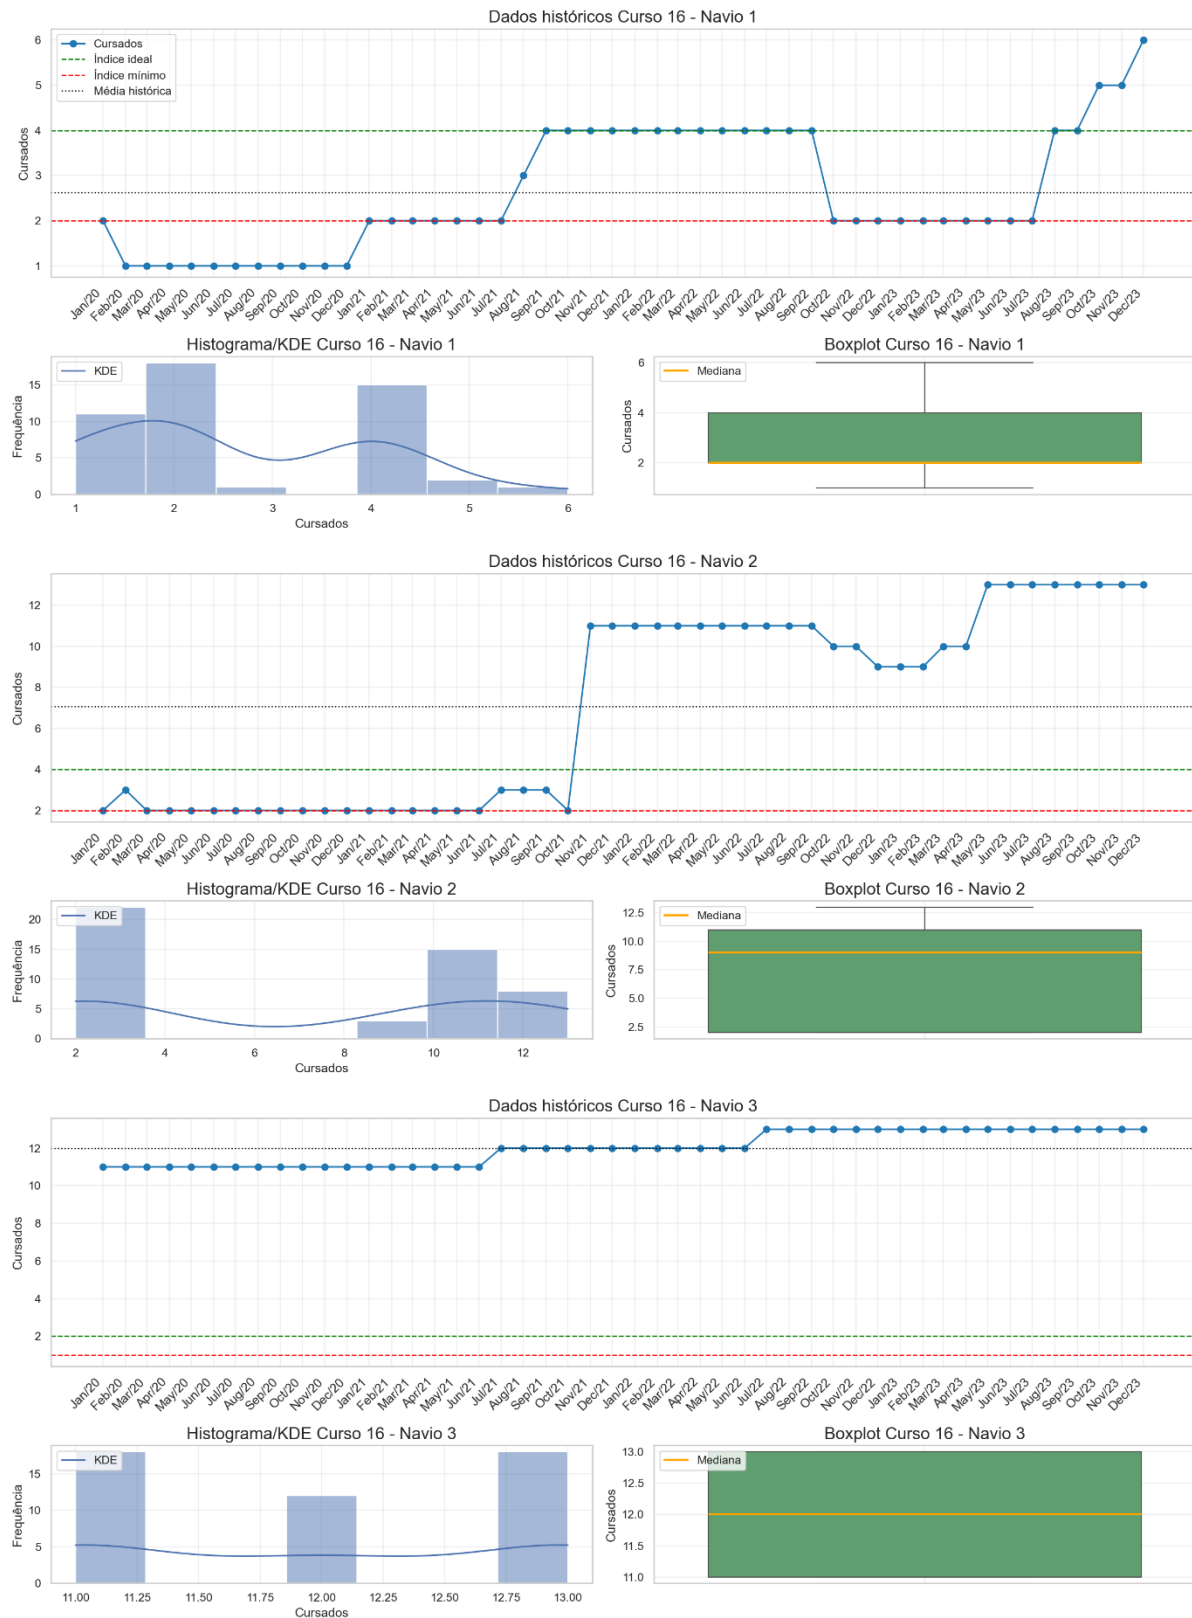


Figura 31 – Análise exploratória do Curso 16

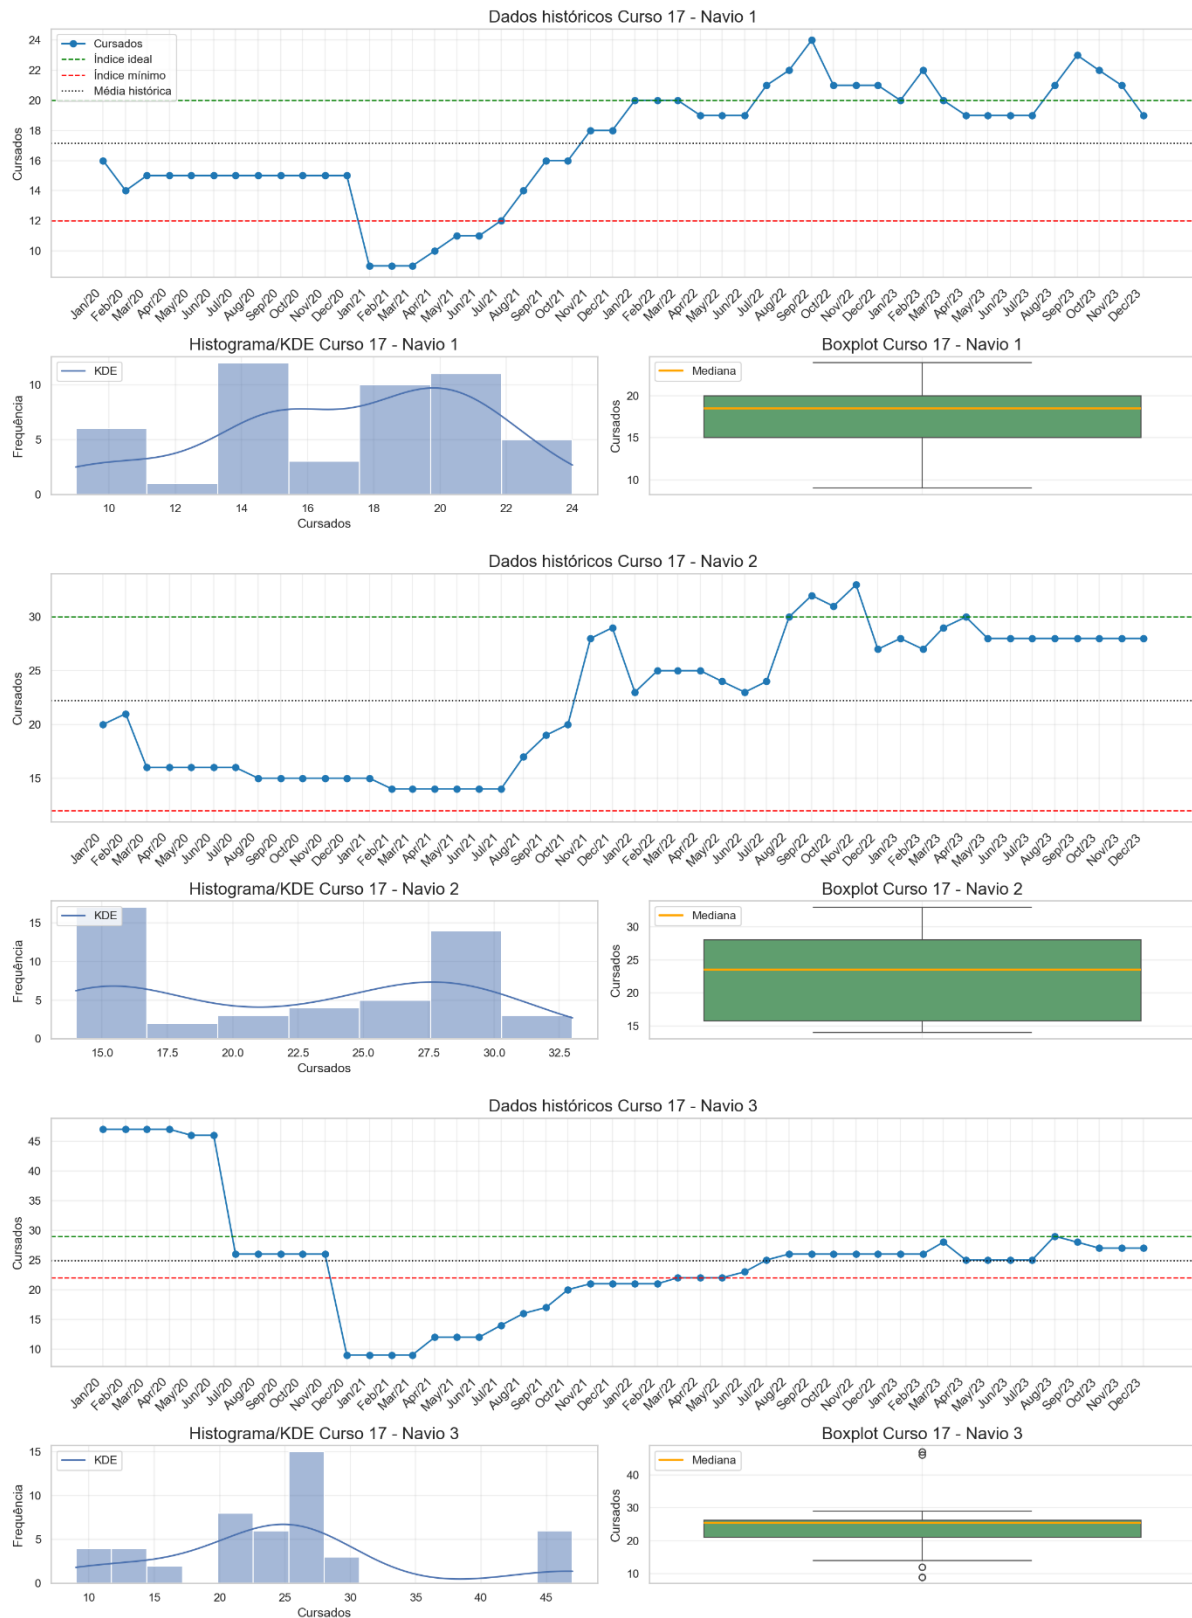


Figura 32 – Análise exploratória do Curso 17



Figura 33 – Análise exploratória do Curso 18

## APENDICE B – TESTES DE ESTACIONARIEDADE

Os testes foram aplicados em todas as séries, considerando a presença de tendência ou não nos dados. Na tabela 8 estão destacados com \* os casos em que o critério foi atingido em ambos os testes, apresentando um total de 5 de 54 cursos (aproximadamente 9% dos casos). Na tabela 9, além dos destaques com \*, há os destaques com \*\*, pois nestes o critério foi atendido no nível da casa dos milésimos/décimos de milésimos - 0,000111421 para o curso 3 do navio 2; 0,0005207285 para o curso 3 do navio 2; 0,000541371 para o curso 15 do navio 3. Considerando uma aproximação não tão detalhada, foram considerados somente os casos destacados em verde, que são 5 de 54 cursos.

Tabela 12 – Verificação de estacionariedade (sem considerar a tendência)

Navio	Curso	ADF p-valor	ADF rejeita H0 (raiz unitária)	KPSS p-valor	KPSS não rejeita H0 (estacionária)	Estacionária segundo critério
Navio 1	Curso 1	0,438121963	FALSO	0,01	FALSO	FALSO
Navio 1	Curso 2	0,025991675	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
Navio 1	Curso 3	0,689768271	FALSO	0,01	FALSO	FALSO
Navio 1	Curso 4	2,40724E-12	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
Navio 1	Curso 5	0,538430961	FALSO	0,01	FALSO	FALSO
Navio 1	Curso 6	0,786439901	FALSO	0,01	FALSO	FALSO
Navio 1	Curso 7	0,019638111	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
Navio 1	Curso 8	0,753847643	FALSO	0,01	FALSO	FALSO
Navio 1	Curso 9	0,142304673	FALSO	0,068998221	VERDADEIRO	FALSO
Navio 1	Curso 10	0,118711437	FALSO	0,1	VERDADEIRO	FALSO
Navio 1	Curso 11	0,778676811	FALSO	0,01	FALSO	FALSO
Navio 1	Curso 12	0,718642433	FALSO	0,013532403	FALSO	FALSO
Navio 1	Curso 13	0,325740506	FALSO	0,1	VERDADEIRO	FALSO
Navio 1	Curso 14	0,4596517	FALSO	0,014082455	FALSO	FALSO
Navio 1	Curso 15	0,282545692	FALSO	0,01503845	FALSO	FALSO
Navio 1	Curso 16	0,931860747	FALSO	0,036357768	FALSO	FALSO
Navio 1	Curso 17	0,649141954	FALSO	0,013001133	FALSO	FALSO
Navio 1	Curso 18	0,89584809	FALSO	0,01	FALSO	FALSO
Navio 2	Curso 1	0,039116365	VERDADEIRO	0,041083061	FALSO	FALSO
Navio 2	Curso 2	0,605811745	FALSO	0,025676456	FALSO	FALSO
Navio 2	Curso 3	0,461120188	FALSO	0,020768757	FALSO	FALSO
Navio 2	Curso 4	0,013959484	VERDADEIRO	0,062237699	VERDADEIRO	VERDADEIRO*
Navio 2	Curso 5	0,586513154	FALSO	0,01	FALSO	FALSO
Navio 2	Curso 6	0,875198798	FALSO	0,01	FALSO	FALSO
Navio 2	Curso 7	0,83712503	FALSO	0,01	FALSO	FALSO
Navio 2	Curso 8	0,878377387	FALSO	0,01	FALSO	FALSO
Navio 2	Curso 9	0,27039522	FALSO	0,099114865	VERDADEIRO	FALSO

<b>Navio 2</b>	Curso 10	0,153399339	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 11	0,074791007	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 12	0,638568674	FALSO	0,030704261	FALSO	FALSO
<b>Navio 2</b>	Curso 13	0,797046698	FALSO	0,01	FALSO	FALSO
<b>Navio 2</b>	Curso 14	0,677456024	FALSO	0,068012882	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 15	0,814871357	FALSO	0,01	FALSO	FALSO
<b>Navio 2</b>	Curso 16	0,773699698	FALSO	0,01	FALSO	FALSO
<b>Navio 2</b>	Curso 17	0,721846504	FALSO	0,01	FALSO	FALSO
<b>Navio 2</b>	Curso 18	0,874458114	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 1	0,794520102	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 2	0,506919441	FALSO	0,033262008	FALSO	FALSO
<b>Navio 3</b>	Curso 3	0,602515236	FALSO	0,048176223	FALSO	FALSO
<b>Navio 3</b>	Curso 4	0,605697938	FALSO	0,01360413	FALSO	FALSO
<b>Navio 3</b>	Curso 5	0,928180115	FALSO	0,014286803	FALSO	FALSO
<b>Navio 3</b>	Curso 6	0,19449951	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 7	0,076197222	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 8	0,931114586	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 9	0,310267391	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 10	0,019678809	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
<b>Navio 3</b>	Curso 11	0,594927544	FALSO	0,015426574	FALSO	FALSO
<b>Navio 3</b>	Curso 12	0,943961445	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 13	0,625642237	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 14	0,617981024	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 15	0,211838933	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 16	0,821982744	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 17	0,732441869	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 18	0,13496478	FALSO	0,01	FALSO	FALSO

Tabela 13 – Verificação da estacionariedade considerando a tendência

Navio	Curso	ADF p-valor	ADF rejeita H0 (raiz unitária)	KPSS p-valor	KPSS não rejeita H0 (estacionária)	Estacionária segundo critério
<b>Navio 1</b>	Curso 1	0,000524811	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
<b>Navio 1</b>	Curso 2	0,124629012	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 3	0,987035215	FALSO	0,043119614	FALSO	FALSO
<b>Navio 1</b>	Curso 4	0,039564866	VERDADEIRO	0,043989356	FALSO	FALSO
<b>Navio 1</b>	Curso 5	0,406083981	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 6	0,401422763	FALSO	0,090623774	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 7	0,105759215	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 8	0,870026512	FALSO	0,08846903	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 9	0,537528666	FALSO	0,01	FALSO	FALSO
<b>Navio 1</b>	Curso 10	0,075958545	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 11	0,867779931	FALSO	0,059521085	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 12	0,494647013	FALSO	0,015550901	FALSO	FALSO
<b>Navio 1</b>	Curso 13	0,55657367	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 14	0,245014249	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 15	6,31708E-06	VERDADEIRO	0,01	FALSO	FALSO

<b>Navio 1</b>	Curso 16	0,004702461	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
<b>Navio 1</b>	Curso 17	0,595780503	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 1</b>	Curso 18	0,323569125	FALSO	0,01606994	FALSO	FALSO
<b>Navio 2</b>	Curso 1	0,126456507	FALSO	0,016615806	FALSO	FALSO
<b>Navio 2</b>	Curso 2	0,609976763	FALSO	0,023931137	FALSO	FALSO
<b>Navio 2</b>	Curso 3	0,049888579**	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO**
<b>Navio 2</b>	Curso 4	3,82641E-05	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
<b>Navio 2</b>	Curso 5	0,867202965	FALSO	0,019813762	FALSO	FALSO
<b>Navio 2</b>	Curso 6	0,173066424	FALSO	0,040039719	FALSO	FALSO
<b>Navio 2</b>	Curso 7	0,063111486	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 8	0,756283234	FALSO	0,01	FALSO	FALSO
<b>Navio 2</b>	Curso 9	0,459922339	FALSO	0,013967261	FALSO	FALSO
<b>Navio 2</b>	Curso 10	0,410786749	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 11	0,246270888	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 12	0,172221101	FALSO	0,01	FALSO	FALSO
<b>Navio 2</b>	Curso 13	0,044792715**	VERDADEIRO	0,074286184	VERDADEIRO	VERDADEIRO**
<b>Navio 2</b>	Curso 14	0,976867458	FALSO	0,014338964	FALSO	FALSO
<b>Navio 2</b>	Curso 15	0,002692509	VERDADEIRO	0,1	VERDADEIRO	VERDADEIRO*
<b>Navio 2</b>	Curso 16	0,373263174	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 17	0,264162611	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 2</b>	Curso 18	0,2173206	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 1	0,970662806	FALSO	0,01	FALSO	FALSO
<b>Navio 3</b>	Curso 2	0,984839126	FALSO	0,018888888	FALSO	FALSO
<b>Navio 3</b>	Curso 3	6,1421E-05	VERDADEIRO	0,09970549	VERDADEIRO	VERDADEIRO*
<b>Navio 3</b>	Curso 4	0,386424279	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 5	0,793382633	FALSO	0,018684942	FALSO	FALSO
<b>Navio 3</b>	Curso 6	0,527562618	FALSO	0,014473053	FALSO	FALSO
<b>Navio 3</b>	Curso 7	0,298518705	FALSO	0,060670667	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 8	0,354962545	FALSO	0,093278904	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 9	0,634022534	FALSO	0,034506674	FALSO	FALSO
<b>Navio 3</b>	Curso 10	0,169594258	FALSO	0,028647216	FALSO	FALSO
<b>Navio 3</b>	Curso 11	0,40106824	FALSO	0,060650442	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 12	0,433568388	FALSO	0,022549878	FALSO	FALSO
<b>Navio 3</b>	Curso 13	0,470727135	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 14	0,303936655	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 15	0,01122013	VERDADEIRO	0,050541371**	VERDADEIRO	VERDADEIRO**
<b>Navio 3</b>	Curso 16	0,389136207	FALSO	0,1	VERDADEIRO	FALSO
<b>Navio 3</b>	Curso 17	0,000290179	VERDADEIRO	0,019493222	FALSO	FALSO
<b>Navio 3</b>	Curso 18	0,715994277	FALSO	0,010384725	FALSO	FALSO



## APÊNDICE C – GRÁFICOS DE ACF/PACF DOS CURSOS

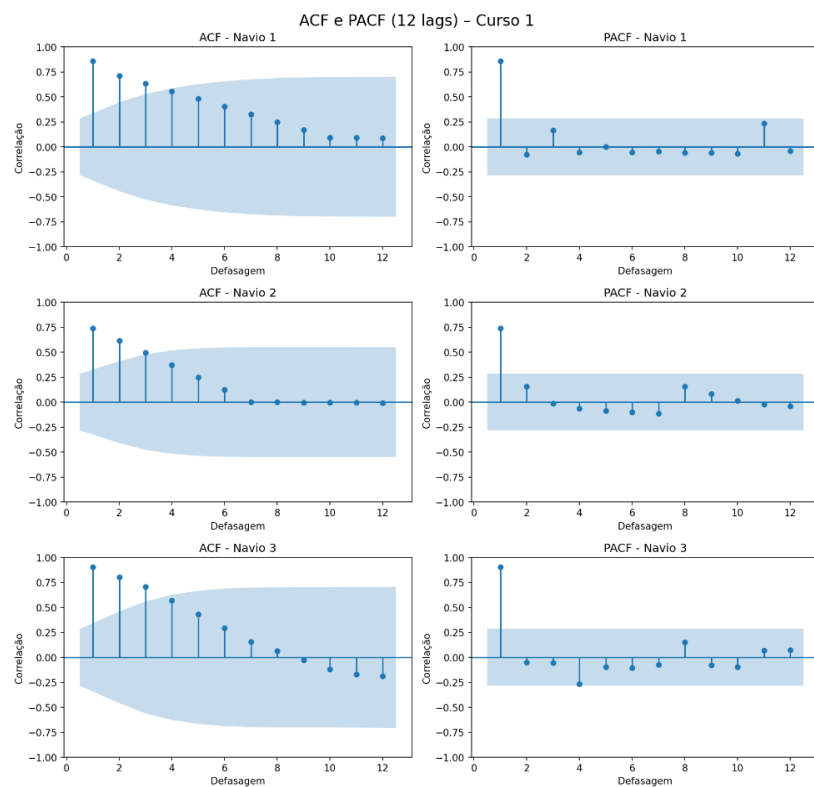


Figura 34 – Gráficos de ACF/PACF para o Curso 1

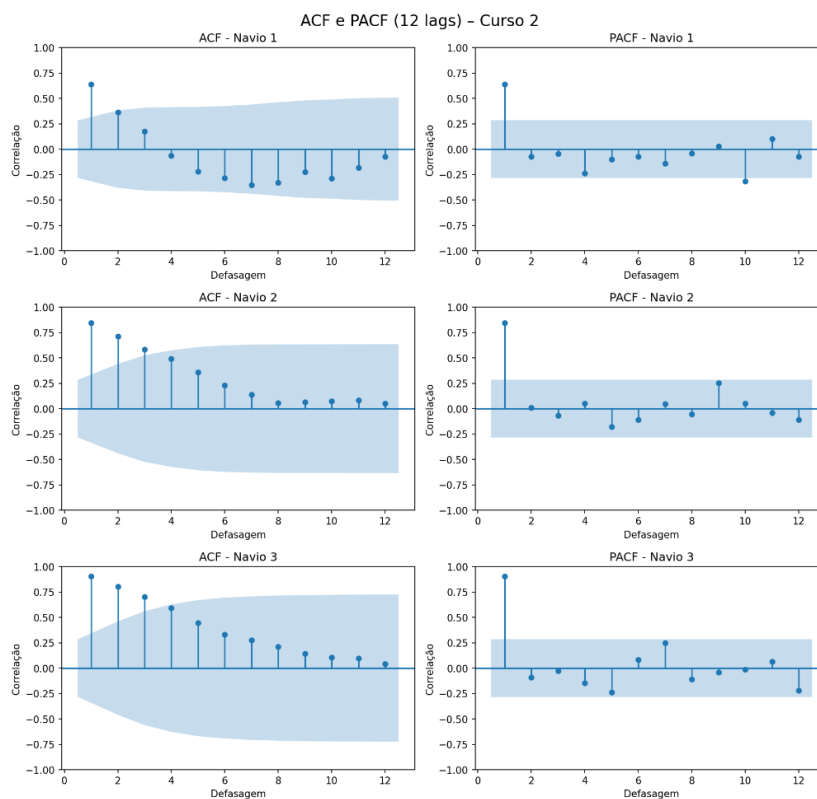


Figura 35 – Gráficos de ACF/PACF para o Curso 2

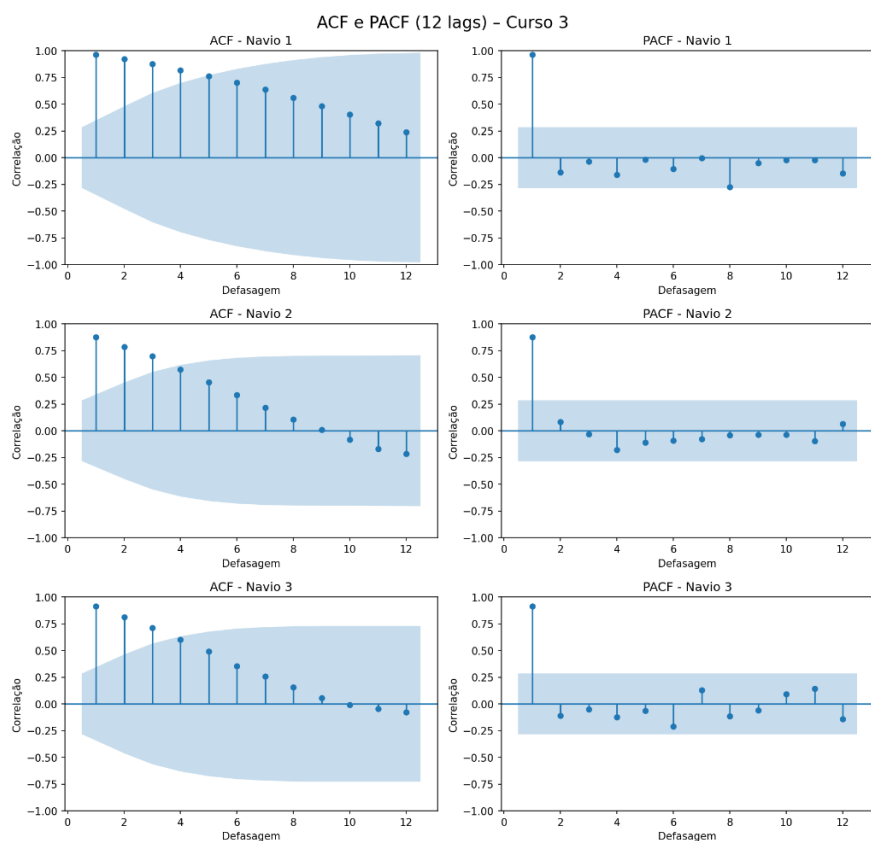


Figura 36 – Gráficos de ACF/PACF para o Curso 3

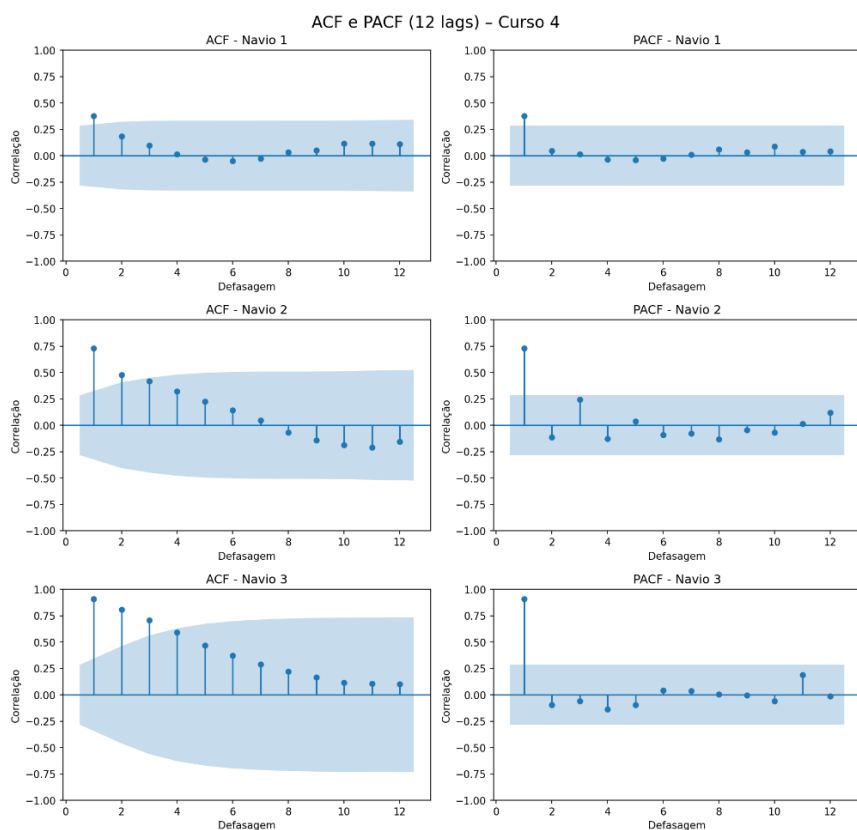


Figura 37 – Gráficos de ACF/PACF para o Curso 4

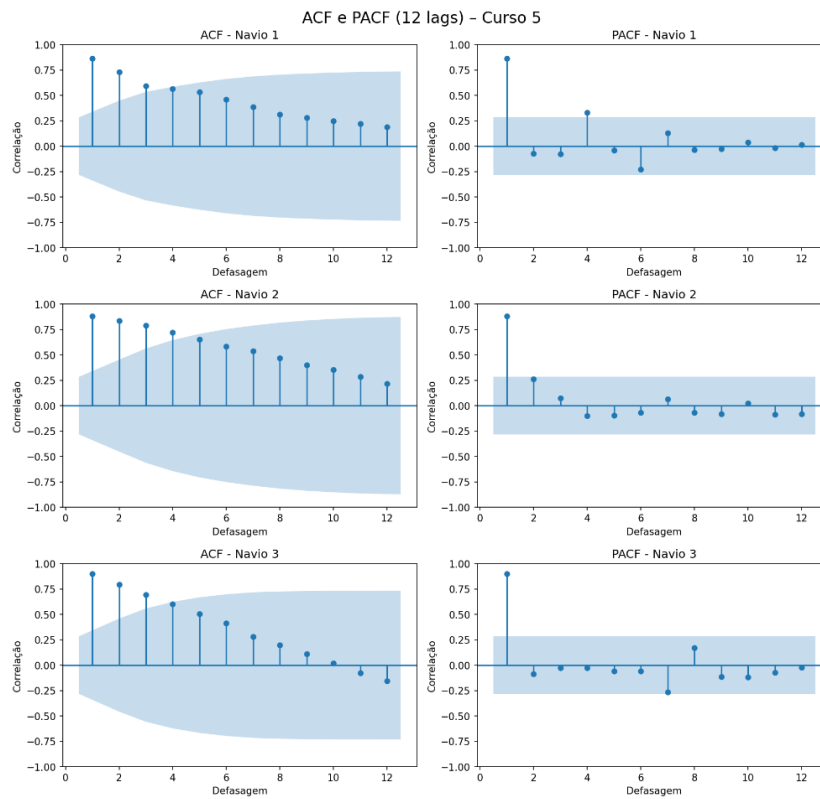


Figura 38 – Gráficos de ACF/PACF para o Curso 5

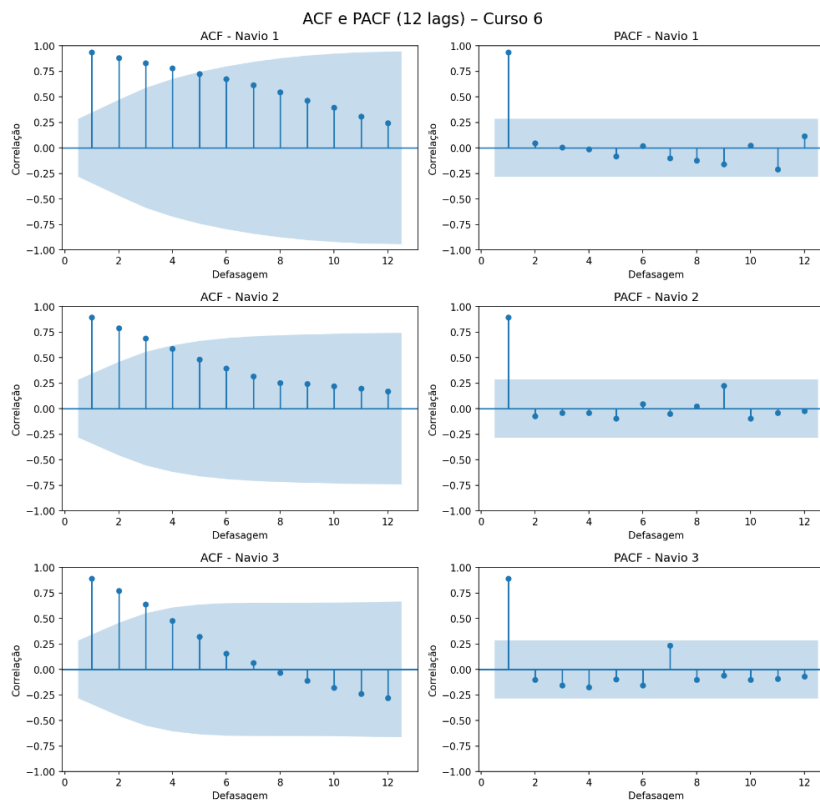


Figura 39 – Gráficos de ACF/PACF para o Curso 6

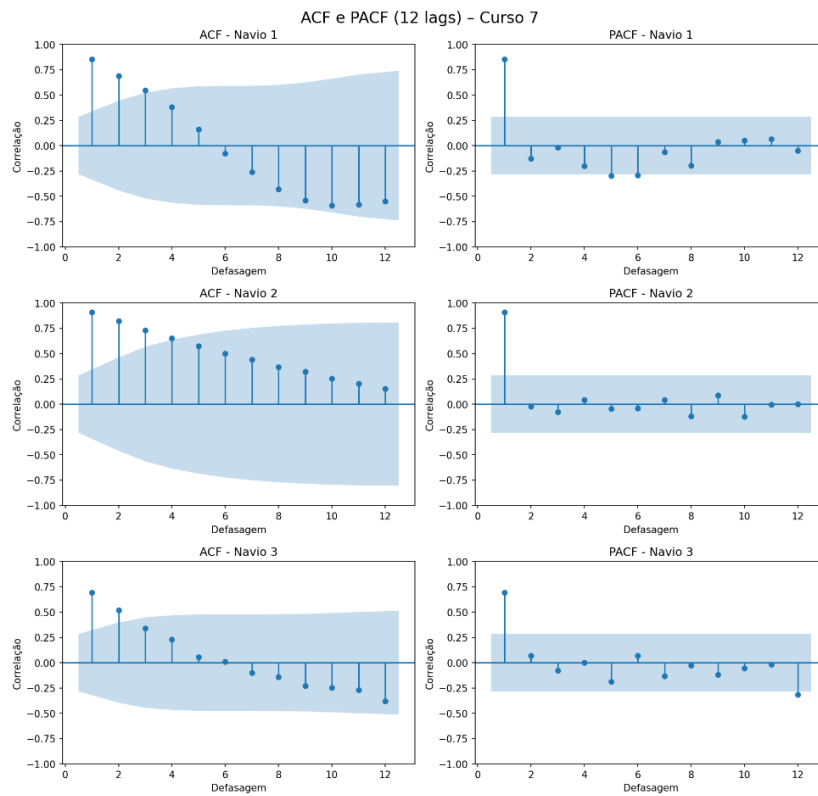


Figura 40 – Gráficos de ACF/PACF para o Curso 7

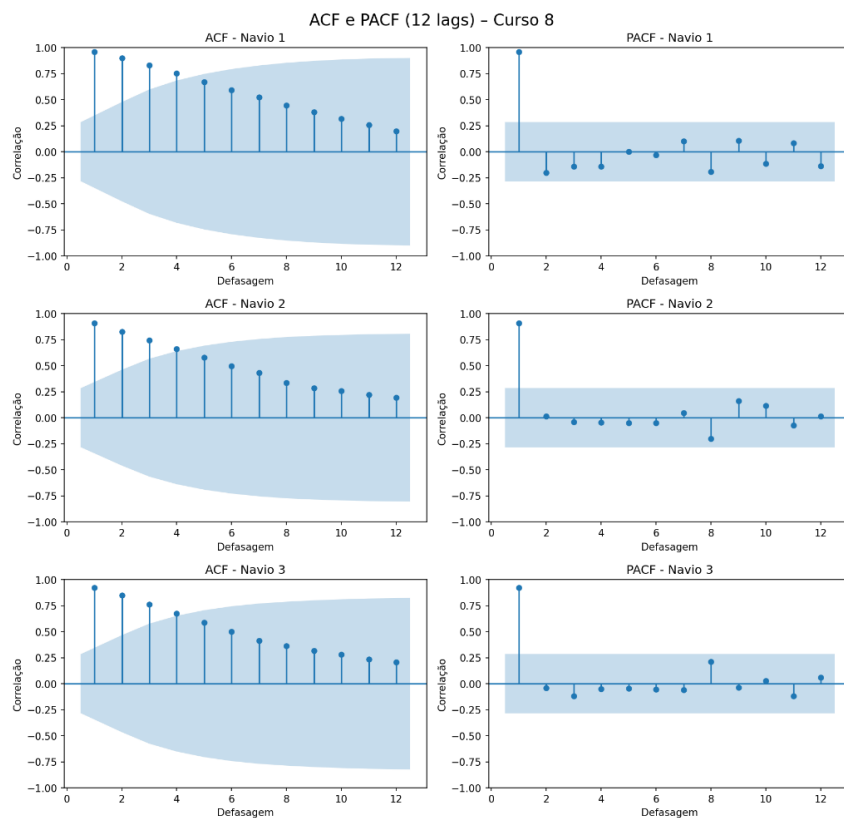


Figura 41 – Gráficos de ACF/PACF para o Curso 8

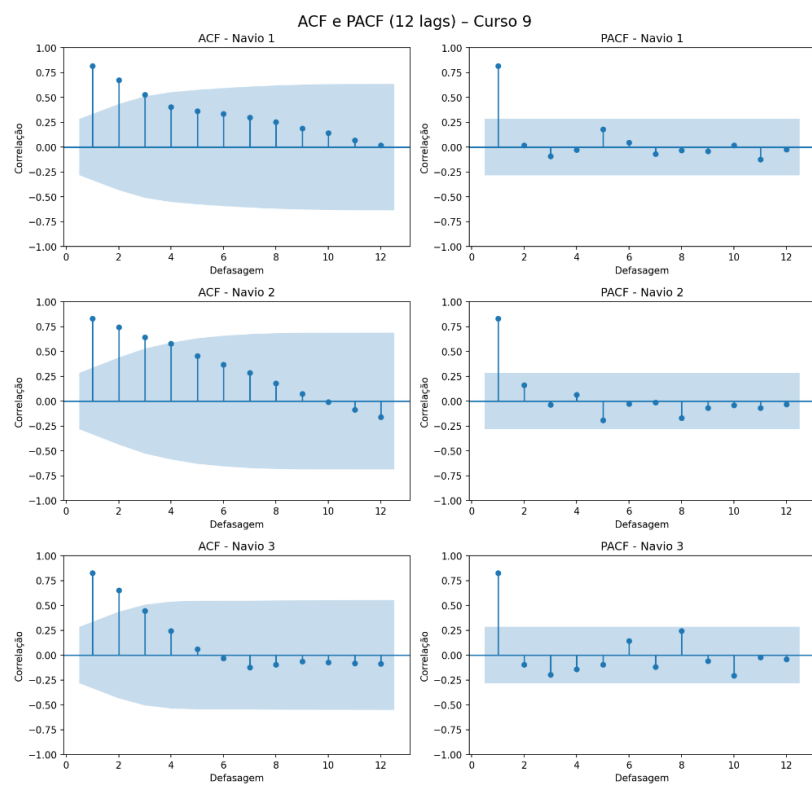


Figura 42 – Gráficos de ACF/PACF para o Curso 9

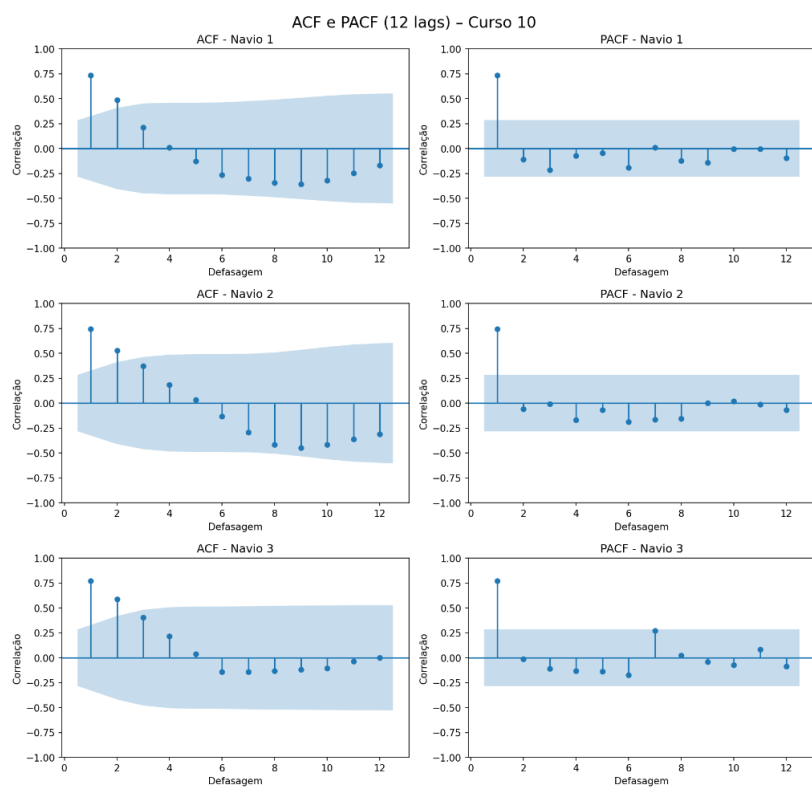


Figura 43 – Gráficos de ACF/PACF para o Curso 10

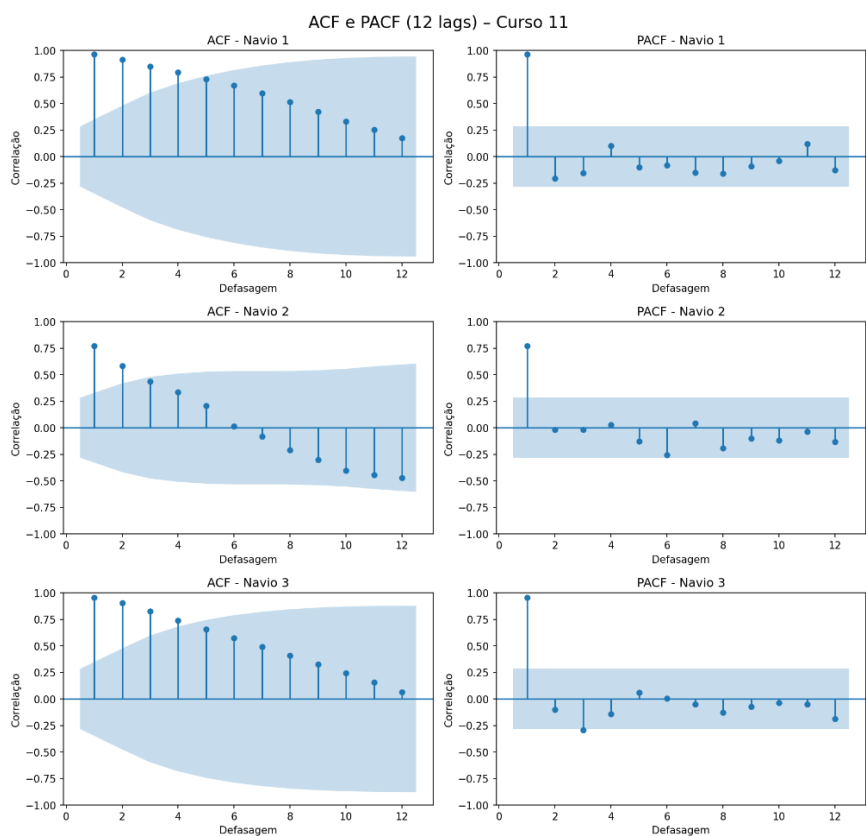


Figura 44 – Gráficos de ACF/PACF para o Curso 11

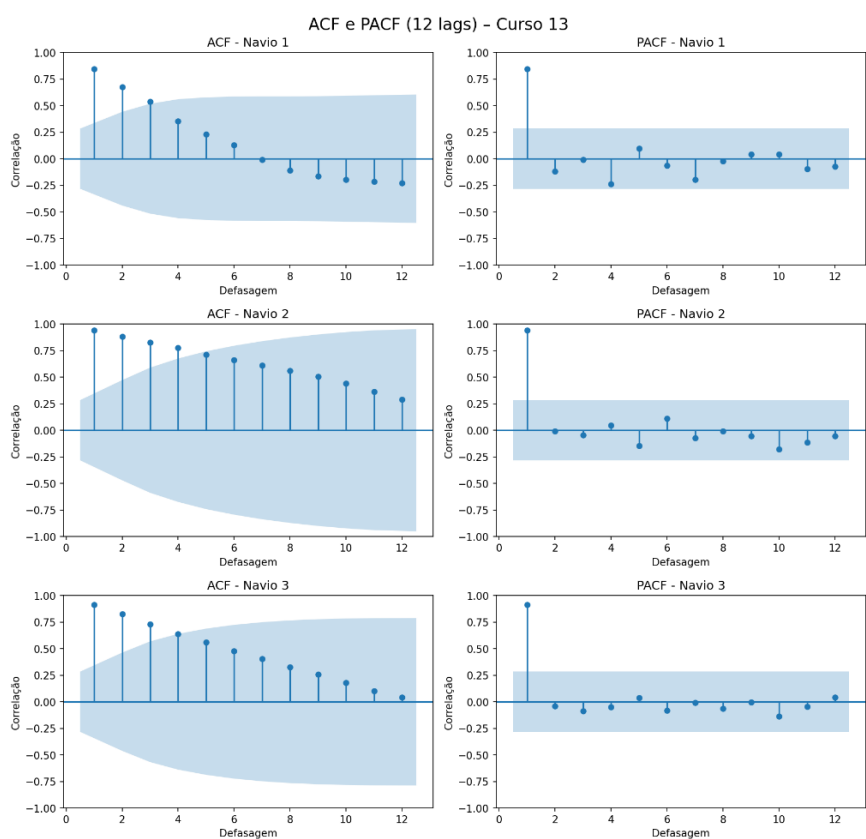


Figura 45 – Gráficos de ACF/PACF para o Curso 13

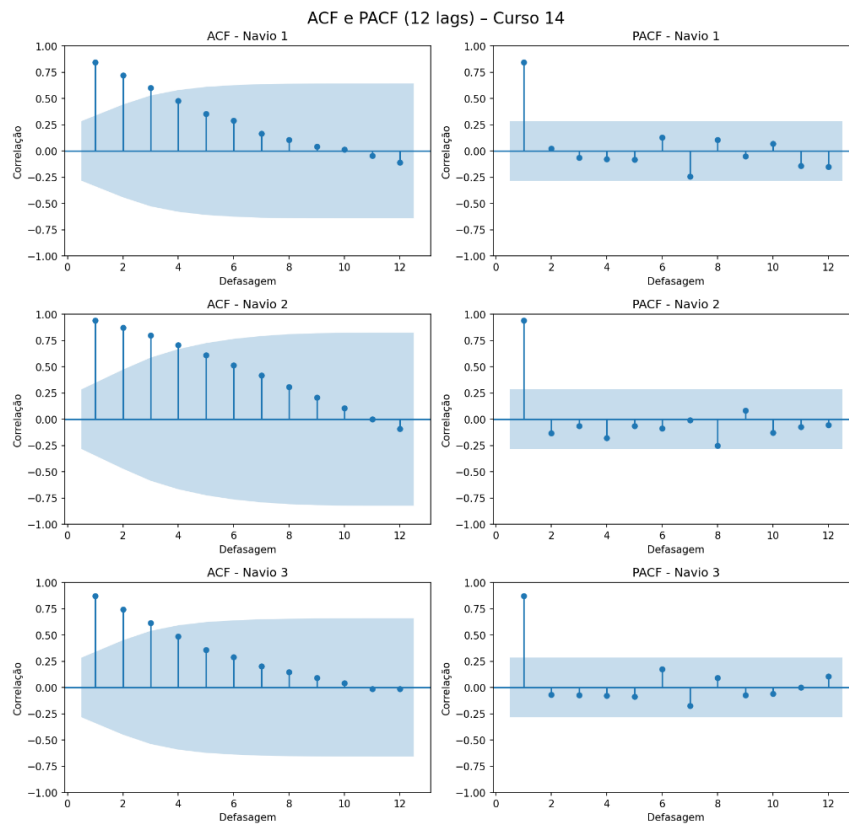


Figura 46 – Gráficos de ACF/PACF para o Curso 14

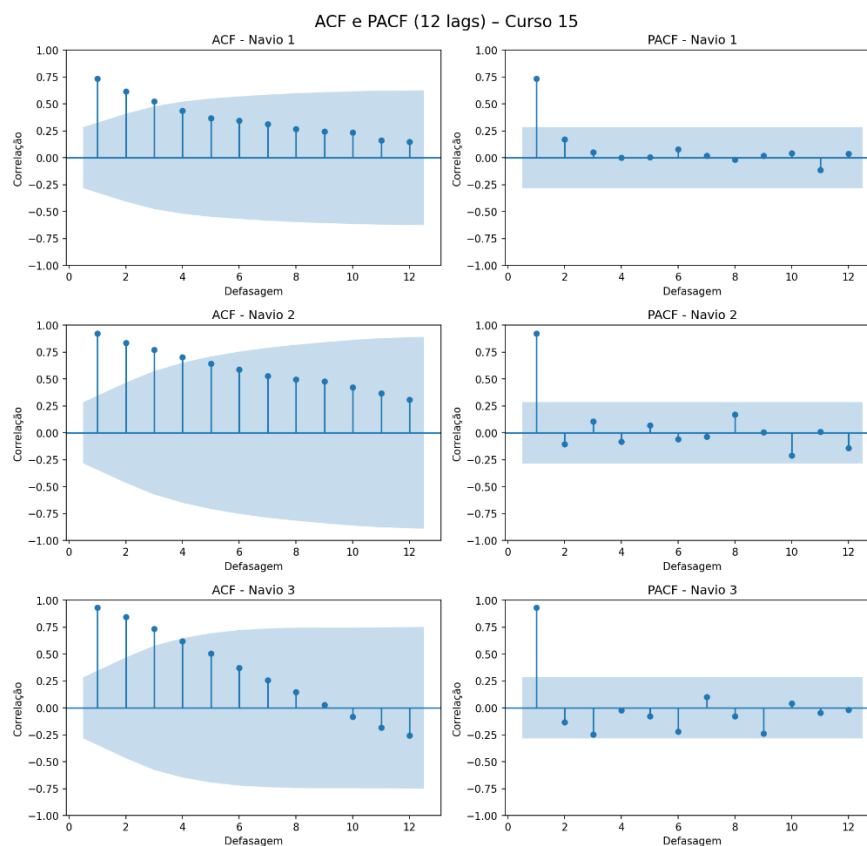


Figura 47 – Gráficos de ACF/PACF para o Curso 15

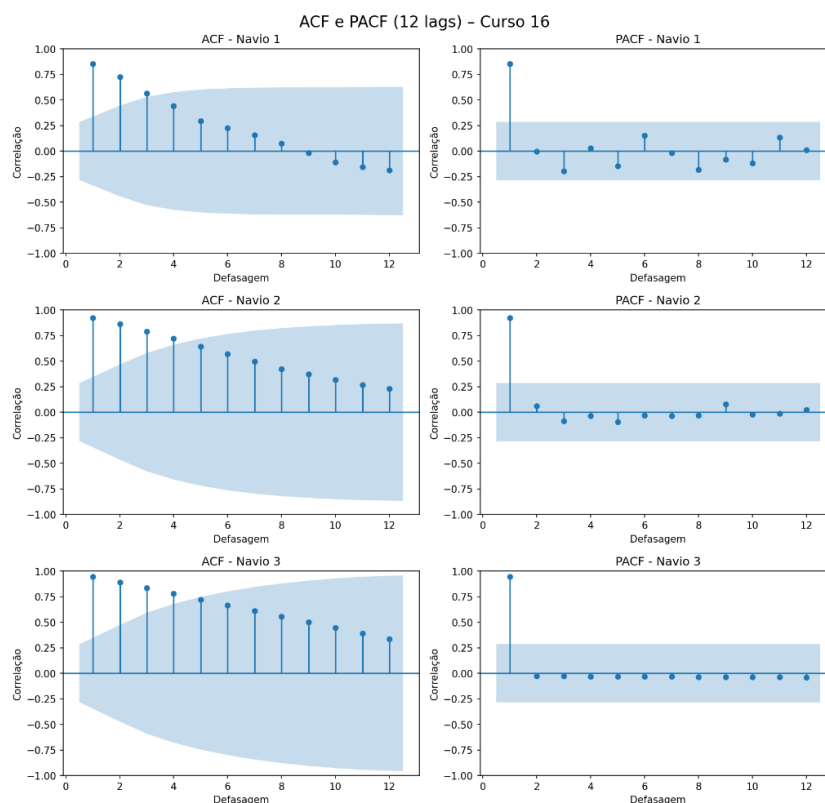


Figura 48 – Gráficos de ACF/PACF para o Curso 16

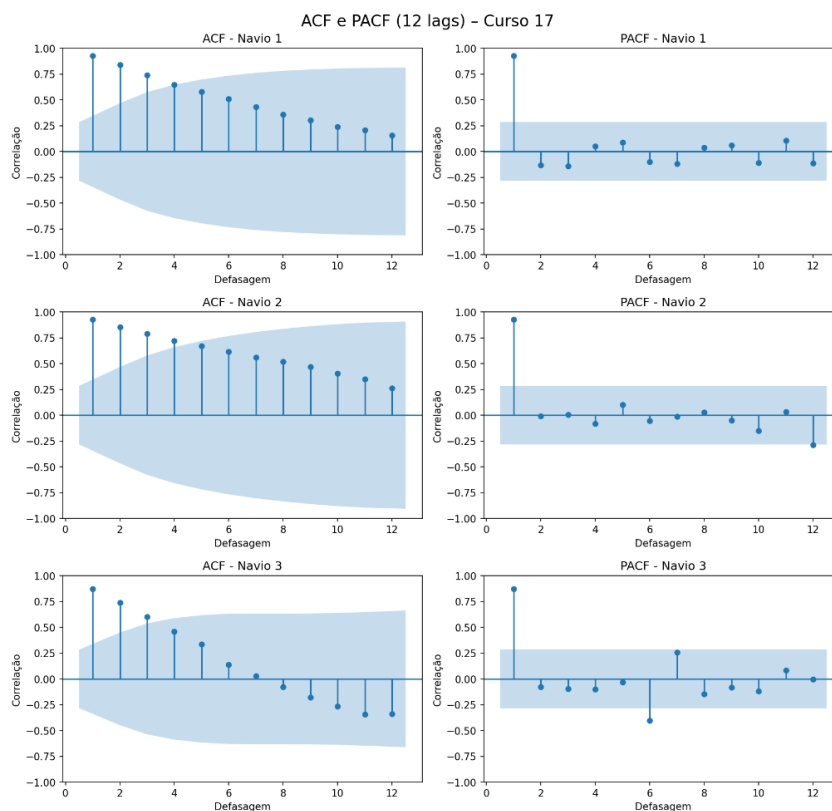


Figura 49 – Gráficos de ACF/PACF para o Curso 17



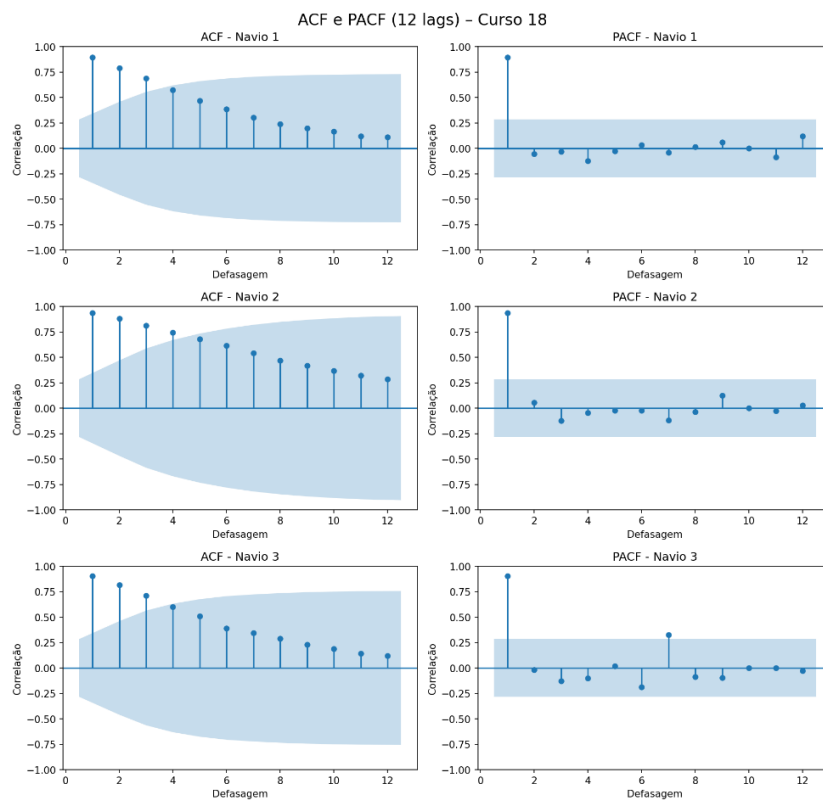


Figura 50 – Gráficos de ACF/PACF para o Curso 18

APÊNDICE D – SIMULAÇÕES DOS CURSOS




Figura 51 – Simulações para o Curso 1




Figura 52 – Simulações para o Curso 2




Figura 53 – Simulações para o Curso 3




Figura 54 – Simulações para o Curso 4




Figura 55 – Simulações para o Curso 5




Figura 56 – Simulações para o Curso 6




Figura 57 – Simulações para o Curso 7




Figura 58 – Simulações para o Curso 8




Figura 59 – Simulações para o Curso 9




Figura 60 – Simulações para o Curso 10

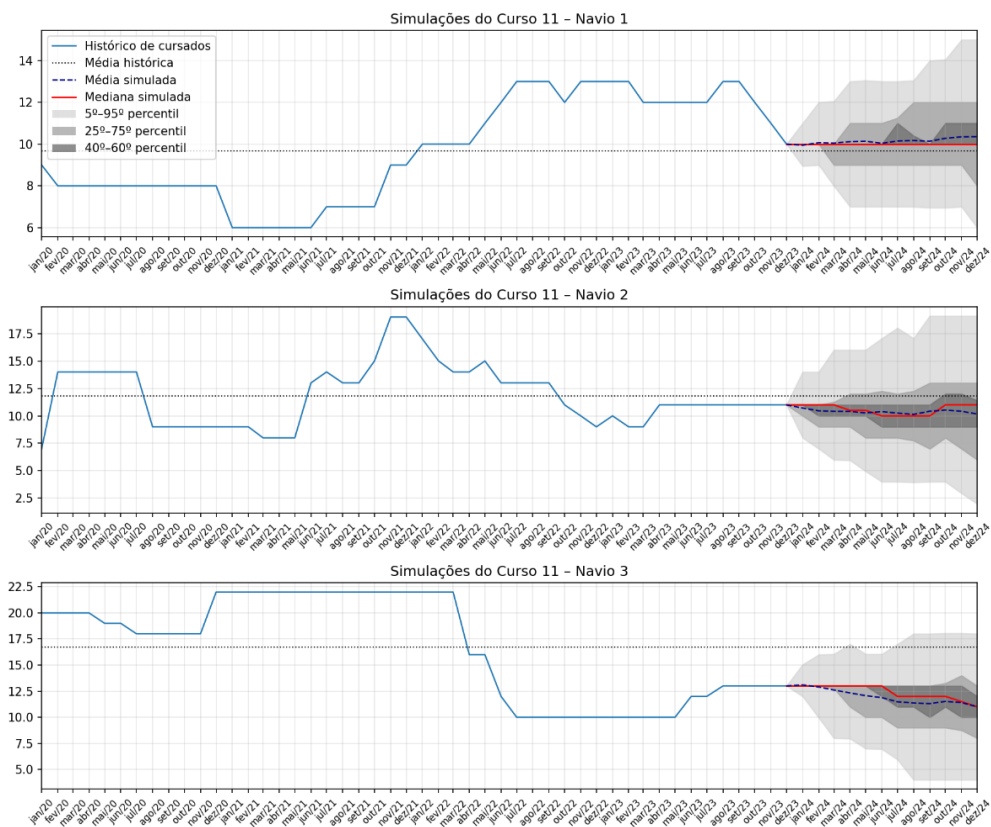


Figura 61 – Simulações para o Curso 11




Figura 62 – Simulações para o Curso 13






Figura 63 – Simulações para o Curso 14

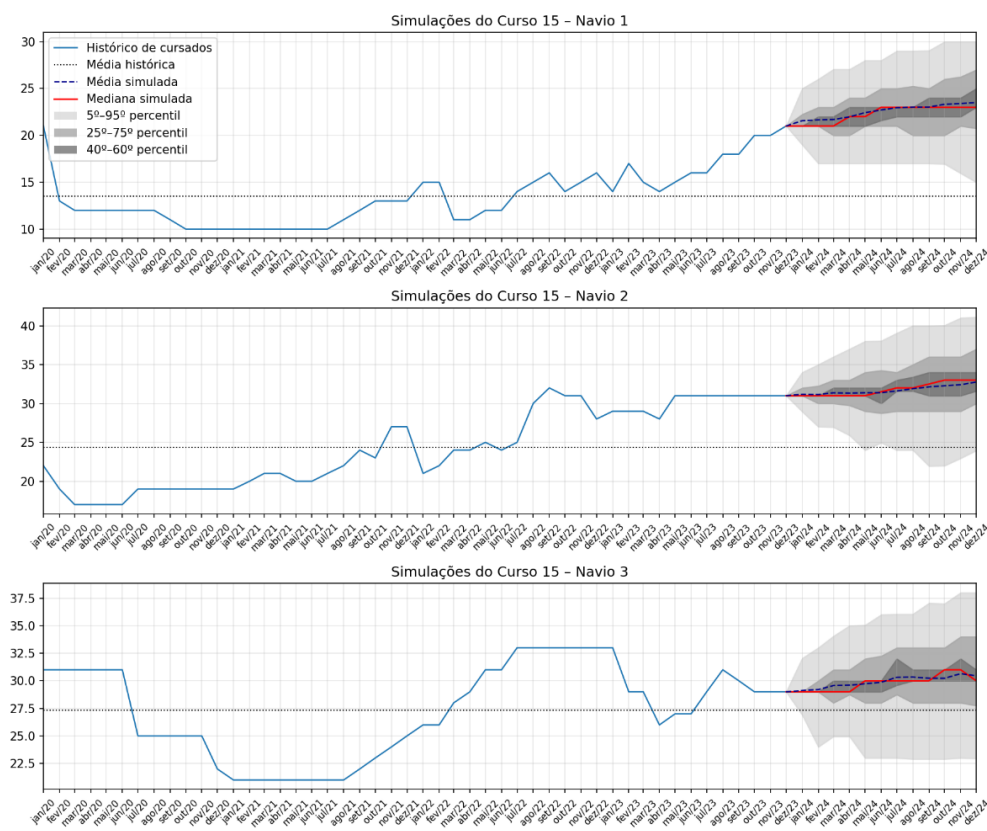


Figura 64 – Simulações para o Curso 15






Figura 65 – Simulações para o Curso 16

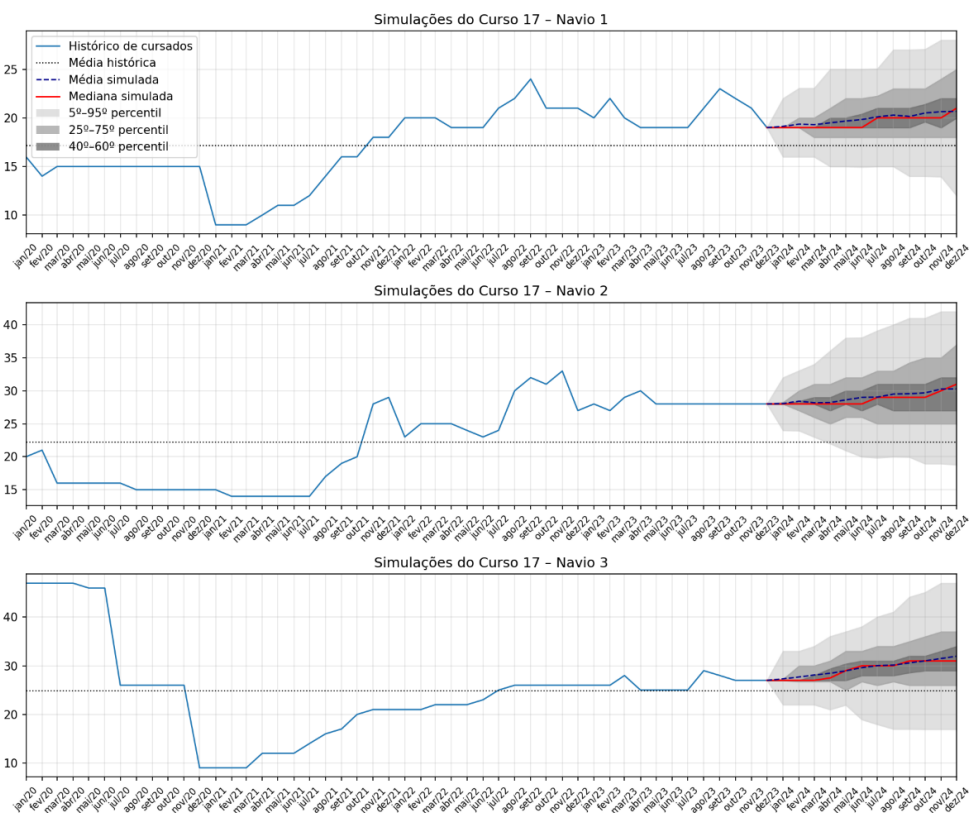


Figura 66 – Simulações para o Curso 17




Figura 67 – Simulações para o Curso 18

## APÊNDICE E – VAGAS ALOCADAS POR TIPO DE DISTRIBUIÇÃO

Alocação de vagas e atingimento de índices ideais, por navio e tipo de distribuição. As tabelas 9, 10 e 11 apresentam quantas vagas cada modelo alocou por curso, sendo que no modelo 4 estão separas por vagas alocadas pela variável de decisão e as vagas sugeridas incluir com a variável de excesso.

Tabela 14 – Vagas alocadas para o Navio 1 por tipo de distribuição.

Navio	Curso	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4		Modelo 5
						Var Decisão	Var Excesso	
1	Curso 1	0	1	1	1	1	0	1
	Curso 2	1	0	1	0	0	0	0
	Curso 3	1	0	2	0	0	0	0
	Curso 4	32	23	23	16	0	26	15
	Curso 5	0	0	0	0	0	0	0
	Curso 6	4	0	6	0	0	0	0
	Curso 7	0	0	0	0	0	0	0
	Curso 8	1	0	1	1	3	0	1
	Curso 9	0	0	0	0	0	0	0
	Curso 10	3	0	0	0	0	0	0
	Curso 11	2	0	0	0	0	0	0
	Curso 12	8	5	6	7	13	0	7
	Curso 13	7	6	12	0	0	0	0
	Curso 14	1	0	0	0	0	0	0
	Curso 15	8	1	3	0	0	0	0
	Curso 16	2	2	4	0	0	0	0
	Curso 17	7	1	8	0	0	0	0
	Curso 18	6	0	0	0	0	0	0

Tabela 15 – Vagas alocadas para o Navio 2 por tipo de distribuição.

Navio	Curso	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4		Modelo 5
						Var Decisão	Var Excesso	
2	Curso 1	0	1	1	1	1	0	1
	Curso 2	1	1	2	0	0	0	0
	Curso 3	1	0	0	0	0	0	0
	Curso 4	34	36	35	68	66	22	64
	Curso 5	0	0	0	0	0	0	0
	Curso 6	17	0	9	0	0	0	0
	Curso 7	2	0	0	0	0	0	0
	Curso 8	1	0	0	0	0	0	0
	Curso 9	2	0	0	0	1	0	0
	Curso 10	5	1	4	3	11	0	3
	Curso 11	1	0	2	0	8	0	0
	Curso 12	8	1	5	4	4	0	4
	Curso 13	6	0	3	0	0	0	0
	Curso 14	1	0	0	0	2	0	1

Curso 15	9	17	10	13	23	0	13
Curso 16	1	0	0	0	0	0	0
Curso 17	11	0	9	1	0	0	1
Curso 18	10	0	0	0	0	0	0

Tabela 16 – Vagas alocadas para o Navio 3 por tipo de distribuição.

Navio	Curso	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4		Modelo 5
						Var Decisão	Var Excesso	
<b>3</b>	Curso 1	2	0	0	0	0	0	0
	Curso 2	1	0	0	0	3	0	0
	Curso 3	2	0	0	0	0	0	0
	Curso 4	47	29	55	29	47	0	34
	Curso 5	0	0	0	0	0	1	0
	Curso 6	11	0	0	0	0	0	0
	Curso 7	1	0	3	0	0	0	0
	Curso 8	1	0	0	0	0	0	0
	Curso 9	0	0	2	1	1	1	1
	Curso 10	5	0	0	0	2	0	0
	Curso 11	5	2	6	0	0	0	0
	Curso 12	7	17	12	12	6	0	12
	Curso 13	26	0	0	0	0	0	0
	Curso 14	0	0	0	0	0	0	0
	Curso 15	9	8	13	11	3	0	11
	Curso 16	1	0	0	0	0	0	0
	Curso 17	9	4	10	0	0	0	0
	Curso 18	7	0	4	0	23	0	0

As tabelas 12,13 e 14 apresentam os índices após a alocação de vagas, e a comparação com o índice ideal de cada curso, destacando com \* os casos em que índice após a distribuição ficou abaixo do ideal. Não houve casos de índices abaixo do mínimo.

Tabela 17 – Índices após a alocação de vagas para o Navio 1 por tipo de distribuição.

Navio	Curso	Índice ideal	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
<b>1</b>	Curso 1	<b>2</b>	1*	2	2	2	2	2
	Curso 2	<b>3</b>	4	3	4	3	3	3
	Curso 3	<b>10</b>	13	12	14	12	12	12
	Curso 4	<b>130</b>	139	130	130	123*	133	122*
	Curso 5	<b>2</b>	2	2	2	2	2	2
	Curso 6	<b>40</b>	48	44	50	44	44	44
	Curso 7	<b>7</b>	11	11	11	11	11	11
	Curso 8	<b>3</b>	4	3	4	4	6	4
	Curso 9	<b>3</b>	7	7	7	7	7	7
	Curso 10	<b>4</b>	10	7	7	7	7	7
	Curso 11	<b>4</b>	14	12	12	12	12	12
	Curso 12	<b>20</b>	16*	13*	14*	15*	21	15*

Curso 13	<b>20</b>	21	20	26	14*	14*	14*
Curso 14	<b>2</b>	4	3	3	3	3	3
Curso 15	<b>15</b>	22	15	17	14*	14*	14*
Curso 16	<b>4</b>	4	4	6	2*	2*	2*
Curso 17	<b>20</b>	26	20	27	19*	19*	19*
Curso 18	<b>12</b>	27	21	21	21	21	21

Tabela 18 - Índices após a alocação de vagas para o Navio 2 por tipo de distribuição.

Navio	Curso	Índice ideal	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
<b>2</b>	Curso 1	<b>2</b>	1*	2	2	2	2	2
	Curso 2	<b>3</b>	3	3	4	2*	2*	2*
	Curso 3	<b>6</b>	8	7	7	7	7	7
	Curso 4	<b>229</b>	227*	229	228*	261	281	257
	Curso 5	<b>2</b>	3	3	3	3	3	3
	Curso 6	<b>50</b>	68	51	60	51	51	51
	Curso 7	<b>8</b>	17	15	15	15	15	15
	Curso 8	<b>3</b>	6	5	5	5	5	5
	Curso 9	<b>3</b>	6	4	4	4	5	4
	Curso 10	<b>4</b>	8	4	7	6	14	6
	Curso 11	<b>10</b>	12	11	13	11	19	11
	Curso 12	<b>20</b>	17*	10*	14*	13*	13*	13*
	Curso 13	<b>30</b>	40	34	37	34	34	34
	Curso 14	<b>2</b>	5	4	4	4	6	5
	Curso 15	<b>45</b>	37*	45	38*	41*	51	41*
	Curso 16	<b>4</b>	11	10	10	10	10	10
	Curso 17	<b>30</b>	41	30	39	31	30	31
	Curso 18	<b>12</b>	36	26	26	26	26	26

Tabela 19 - Índices após a alocação de vagas para o Navio 3 por tipo de distribuição.

Navio	Curso	Índice ideal	Real	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
<b>3</b>	Curso 1	<b>5</b>	8	6	6	6	6	6
	Curso 2	<b>3</b>	7	6	6	6	9	6
	Curso 3	<b>6</b>	15	13	13	13	13	13
	Curso 4	<b>292</b>	310	292	318	292	310	297
	Curso 5	<b>2</b>	6	6	6	6	7	6
	Curso 6	<b>40</b>	75	64	64	64	64	64
	Curso 7	<b>20</b>	21	20	23	20	20	20
	Curso 8	<b>3</b>	5	4	4	4	4	4
	Curso 9	<b>3</b>	3	3	5	4	5	4
	Curso 10	<b>4</b>	12	7	7	7	9	7
	Curso 11	<b>12</b>	15	12	16	10*	10*	10*
	Curso 12	<b>30</b>	20*	30	25*	25*	19*	25*
	Curso 13	<b>47</b>	104	78	78	78	78	78

Curso 14	<b>2</b>	5	5	5	5	5	5
Curso 15	<b>41</b>	35*	34*	39*	37*	29*	37*
Curso 16	<b>2</b>	14	13	13	13	13	13
Curso 17	<b>29</b>	34	29	35	25*	25*	25*
Curso 18	<b>8</b>	17	10	14	10	33	10