



UNIVERSIDADE FEDERAL DO PARANÁ

CÉSAR EDUARDO MACIEL

APRENDIZADO POR REFORÇO APLICADO AO PROBLEMA DE
ALOCAÇÃO DE BERÇOS NO PORTO DE PARANAGUÁ E ANTONINA

CURITIBA

2025

CÉSAR EDUARDO MACIEL

APRENDIZADO POR REFORÇO APLICADO AO PROBLEMA DE
ALOCÇÃO DE BERÇOS NO PORTO DE PARANAGUÁ E ANTONINA

Dissertação apresentada ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia da Universidade Federal do Paraná, como requisito parcial para a obtenção do título de Mestre em Métodos Numéricos em Engenharia.

Orientador: Prof. Dr. Eduardo Tadeu Bacalhau

CURITIBA
2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Maciel, César Eduardo

Aprendizado por reforço aplicado ao problema de alocação de berços no Porto de Paranaguá e Antonina / César Eduardo Maciel. – Curitiba, 2025.
1 recurso on-line : PDF.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-Graduação em Métodos Numéricos em Engenharia.

Orientador: Eduardo Tadeu Bacalhau

1. Portos – Paranaguá (PR). 2. Portos – Antonina (PR). 3. Processo decisório. 4. Inteligência artificial – Aplicações educacionais. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Métodos Numéricos em Engenharia. III. Bacalhau, Eduardo Tadeu. IV. Título.

Bibliotecário: Douglas Lenon da Silva CRB-9/1892

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **CÉSAR EDUARDO MACIEL**, intitulada: **Aprendizado por Reforço Aplicado ao Problema de Alocação de Berços no Porto de Paranaguá e Antonina**, sob orientação do Prof. Dr. EDUARDO TADEU BACALHAU, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 22 de Dezembro de 2025.

Assinatura Eletrônica

06/01/2026 14:24:54.0

EDUARDO TADEU BACALHAU

Presidente da Banca Examinadora

Assinatura Eletrônica

06/01/2026 20:11:08.0

CASSIUS TADEU SCARPIN

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

09/01/2026 08:14:38.0

FLAVIA BARBOSA

Avaliador Externo (FACULDADE DE ECONOMIA DA UNIVERSIDADE DO PORTO)

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **CÉSAR EDUARDO MACIEL**, intitulada: **Aprendizado por Reforço Aplicado ao Problema de Alocação de Berços no Porto de Paranaguá e Antonina**, sob orientação do Prof. Dr. EDUARDO TADEU BACALHAU, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 22 de Dezembro de 2025.

Assinatura Eletrônica

06/01/2026 14:24:54.0

EDUARDO TADEU BACALHAU

Presidente da Banca Examinadora

Assinatura Eletrônica

06/01/2026 20:11:08.0

CASSIUS TADEU SCARPIN

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

09/01/2026 08:14:38.0

FLAVIA BARBOSA

Avaliador Externo (FACULDADE DE ECONOMIA DA UNIVERSIDADE DO PORTO)

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me mantido na trilha certa durante este projeto, concedendo saúde e forças para chegar até o final.

Ao meu orientador, Prof. Dr. Eduardo Tadeu Bacalhau, pela orientação atenta, pelo acompanhamento constante e pela paciência ao longo desta jornada.

Aos meus pais, José Carlos Maciel e Rita de Cássia Marinho Maciel, que sempre estiveram ao meu lado, oferecendo apoio incondicional em toda a minha trajetória.

Aos professores que, em diferentes momentos da pós-graduação, compartilharam conhecimento e apoio.

Aos colegas de curso, pelos momentos vividos e pela parceria.

Ao Programa de Pós-Graduação em Métodos Numéricos em Engenharia (PPGMNE), da Universidade Federal do Paraná, por todo suporte e incentivo.

*"Não é o mais forte que sobrevive, nem o mais inteligente,
mas o que melhor se adapta às mudanças."
(Charles Darwin)*

*"Nenhum vento é favorável para aquele que não sabe aonde vai."
(Sêneca)*

RESUMO

O Problema de Alocação de Berços (PAB) é um dos principais desafios operacionais enfrentados por terminais portuários, especialmente em contextos com alta variabilidade de carga, múltiplos operadores e restrições físicas, como ocorre no sistema da APPA (Administração dos Portos de Paranaguá e Antonina). A alocação eficiente dos navios aos berços impacta diretamente o tempo de espera, o uso da infraestrutura e a fluidez da cadeia logística. Diante da natureza estocástica do ambiente portuário e das limitações dos métodos determinísticos tradicionais, esta dissertação propõe a modelagem do PAB como um Processo de Decisão Sequencial (SDP), resolvido por meio de Aprendizado por Reforço (Reinforcement Learning – RL). A abordagem considera estados definidos por parâmetros operacionais reais, como tipo de carga, tempo de manuseio, configuração dos berços e tempos de troca entre tipos de operação. A abordagem incorpora técnicas de clusterização funcional para reduzir o espaço de estados e melhorar a especialização das políticas aprendidas. O treinamento é realizado com base em recompensas projetadas para maximizar a ocupação dos berços e minimizar o tempo de espera das embarcações. Os resultados obtidos incluem ganhos significativos de eficiência operacional em relação a políticas tradicionais, como *First-In First-Out* (FIFO) e *Priority of Handling Time* (PHT), com destaque para uma redução média de aproximadamente 37% nos tempos de espera das embarcações, além de escalabilidade e robustez frente a incertezas operacionais. Esta abordagem contribui para o avanço de soluções baseadas em inteligência artificial no setor portuário e pode ser replicada em outros terminais com características similares.

Palavras-chave: alocação de berços; aprendizado por reforço; portos; processo de decisão sequencial; inteligência artificial.

ABSTRACT

The Berth Allocation Problem (BAP) is one of the main operational challenges faced by port terminals, especially in contexts with high cargo variability, multiple operators, and physical constraints, as observed in the APPA system (Administration of the Ports of Paranaguá and Antonina). Efficient allocation of vessels to berths directly impacts waiting times, infrastructure utilization, and the fluidity of the logistics chain. Considering the stochastic nature of the port environment and the limitations of traditional deterministic methods, this dissertation proposes modeling the BAP as a Sequential Decision Process (SDP), solved through Reinforcement Learning (RL). The approach considers states defined by real operational parameters, such as cargo type, handling time, berth configuration, and switching times between different types of operations. The model incorporates functional clustering techniques to reduce the state space and improve the specialization of the learned policies. The training process is realized using reward functions designed to maximize berth occupancy and minimize vessel waiting times. The results achieved include significant operational efficiency gains compared to traditional policies such as First-In First-Out (FIFO) and Priority of Handling Time (PHT), with emphasis on an average reduction of approximately 37% in vessel waiting times, in addition to improved scalability and robustness in the face of operational uncertainties. This approach contributes to the advancement of artificial-intelligence-based solutions in the port sector and can be replicated in other terminals with similar characteristics.

Keywords: berth allocation; reinforcement learning; ports; sequential decision process; artificial intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Organização dos berços de atracação na APPA	26
Figura 2 – Fluxograma do processo de simulação. A cada ciclo horário, o sistema observa o estado atual, consulta a Q-Table correspondente ao cluster do navio, seleciona a ação com maior valor esperado, verifica sua viabilidade operacional e atualiza o estado do sistema até o fim do horizonte de simulação.	46
Figura 3 – Variância explicada pelas componentes principais (PCA).	50
Figura 4 – Método do cotovelo aplicado ao k-means.	51
Figura 5 – Resultado da PCA e agrupamento dos berços.	51
Figura 6 – Mapa de calor da distribuição de berços para $k = 5$ clusters, obtida por AG.	53
Figura 7 – Desempenho médio das combinações de α e γ na estrutura de 5 clusters. .	56
Figura 8 – Redução percentual do tempo total em função dos hiperparâmetros α e γ , para clusters 5–8.	57
Figura 9 – Comparação desempenho RL $\alpha = 0.9 / \gamma = 0.9$	58
Figura 10 – Redução média por fila de navios e cluster	58
Figura 11 – Redução média por fila de navios e hiperparâmetros	58
Figura 12 – Comparação desempenho RL $\alpha = 0.9 / \gamma = 0.9$	59
Figura 13 – Diagrama de Gantt da ocupação dos berços (FIFO) – Horizonte 24 h . . .	60
Figura 14 – Diagrama de Gantt da ocupação dos berços (RL – Cluster 5) – Horizonte 24 h	60
Figura 15 – Redução percentual média por combinação de α e γ	65
Figura 16 – Desempenho médio por número de clusters e horizonte de simulação	65
Figura 17 – Redução média por volume de navios e número de clusters	66
Figura 18 – Redução média por volume de navios e hiperparâmetros	67
Figura 19 – Diagrama de Gantt da ocupação dos berços (FIFO) – Horizonte 48h	67
Figura 20 – Diagrama de Gantt da ocupação dos berços (RL – Cluster 5) – Horizonte 48h	68
Figura 21 – Redução por cluster	73
Figura 22 – Redução por fila de navios	73
Figura 23 – Comparação desempenho RL $\alpha = 0. / \gamma = 0.9$	74

LISTA DE TABELAS

Tabela 1 – Instalações portuárias da APPA	26
Tabela 2 – Exemplo de Restrições e Preferências de Berços	48
Tabela 3 – Instância 5 Navios	49
Tabela 4 – Análise comparativa da clusterização por AG	53
Tabela 5 – Complexidade computacional das tabelas Q por tamanho do <i>cluster</i>	55
Tabela 6 – Resultados observados para horizonte de 24 horas	59
Tabela 7 – Melhores 10 resultados observados para diferentes horizontes de simulação	64
Tabela 8 – Comparativo Estrutural FIFO \times RL – Horizonte de 48 horas	70
Tabela 9 – Resultados para horizontes de simulação maiores (ordenados por número de navios)	73
Tabela 10 – Resultados médios para horizonte de 24h	82
Tabela 11 – Resultados médios para horizonte de 48h	88
Tabela 12 – Resultados médios para horizonte de 72h	94
Tabela 13 – Resultados médios para horizonte de 168h	100

LISTA DE ABREVIATURAS E SIGLAS

ACO	Ant Colony Optimization
AG	Algoritmo Genético
APPA	Administração dos Portos de Paranaguá e Antonina
BCO	Bee Colony Optimization
DQN	Deep Q-Network
DRO	Distributionally Robust Optimization
ETA	Estimated Time of Arrival
FIFO	First In, First Out
HT	Handling Time
ML	Machine Learning
MDRPTW	Multi-Depot Vehicle Routing Problem with Time Windows
MAS	Multi-Agent Systems
PAB	Problema de Alocação de Berços
PABDS	Problema de Alocação de Berços Discreto Estático
PABDD	Problema de Alocação de Berços Discreto Dinâmico
PABDE	Problema de Alocação de Berços Discreto Estocástico
PCA	Principal Components Analysis (Análise de Componentes Principais)
PHT	Priority of Handling Time
PSO	Particle Swarm Optimization
Q	Q-learning
RL	Reinforcement Learning (Aprendizado por Reforço)
RO	Robust Optimization
SDP	Sequential Decision Process (Processo de Decisão Sequencial)
SP	Stochastic Programming
UNCTAD	United Nations Conference on Trade and Development

LISTA DE SÍMBOLOS

S	Conjunto de estados possíveis
s^t	Vetor de estado no instante t
s_j^t	Tempo restante de atendimento no berço j no instante t
s_{zero}	Estado inicial ou berço livre ($s_j^t = 0$)
$ S $	Cardinalidade do conjunto de estados
A	Conjunto de ações possíveis
a_k^t	Ação k tomada no instante t
a_{zero}	Ação de não alocação (0,0,0)
$ A $	Cardinalidade do conjunto de ações
b_j	Identificador do berço j
c_i	Tipo de carga do navio i
d	Indicador de atraso da ação (0 = sem atraso, 1 = com atraso)
$R(a_k^t, s^t)$	Recompensa obtida ao aplicar a ação a_k^t no estado s^t
p	Probabilidade de redução do tempo de serviço em cada passo
δ	Redução aleatória do tempo de serviço (horas)
$Q(s,a)$	Valor esperado de retorno para o par estado–ação
α	Taxa de aprendizado (0,1]
γ	Fator de desconto (0,1]
ϵ	Taxa de exploração da política ϵ -greedy
b	Número de berços em um cluster
m	Número de mercadorias em um cluster
K	Número de clusters no Algoritmo Genético
B_i	Conjunto de berços pertencentes ao cluster i

N	Conjunto de navios $N = \{1, 2, \dots, n\}$
B	Conjunto de berços $B = \{1, 2, \dots, b\}$
$\text{fitness}(c)$	Valor da função de aptidão de um cromossomo c no AG

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	18
2	FORMULAÇÃO DO PROBLEMA	19
2.1	Revisão Bibliográfica	19
2.1.1	PAB Discreto Estático (PABDS)	19
2.1.2	PAB Discreto Dinâmico (PABDD)	20
2.1.3	PAB Discreto Estocástico (PABDE)	22
2.1.4	Aprendizado de Máquina Aplicado ao PAB	23
2.2	Associação de Portos de Paranaguá e Antonina (APPA)	25
2.3	Problema de Alocação de Berços (PAB)	27
2.3.1	Formulação Matemática do PAB Discreto Dinâmico	28
3	APRENDIZADO POR REFORÇO	31
3.1	Processo de Decisão Sequencial	32
3.1.1	Parâmetros do Aprendizado por Reforço	32
3.2	Aprendizado por Reforço Adaptado	34
3.2.1	Análise de Complexidade	35
3.2.2	Clusterização dos Berços	36
3.2.3	Análise de Componentes Principais (PCA)	37
3.2.4	Algoritmo Genético (AG)	38
3.2.5	Treinamento por <i>Cluster</i>	40
3.2.6	Q-Table	41
3.2.7	Processo de Simulação	43
4	ESTUDOS DE CASOS E EXPERIMENTOS COMPUTACIONAIS	47
4.1	Dados e Pré-processamento	47
4.2	Instâncias simuladas	48
4.3	Experimento I — Processo de Divisão de <i>Cluster</i>	49
4.3.1	Análise de Componentes Principais (PCA) e Agrupamento com k-means	49
4.3.2	Clusterização Funcional com Algoritmo Genético (AG)	52
4.4	Escalabilidade Computacional do Espaço de Estados	54
4.5	Experimento II — Validação do Algoritmo RL	55
4.6	Análise Consolidada dos Resultados Experimentais	75
5	CONCLUSÕES	76
	Referências	78

Apêndice A — Resultados Detalhados das Simulações	82
--	-----------

1 INTRODUÇÃO

O transporte aquaviário desempenha papel essencial no comércio internacional, movimentando aproximadamente 80% do volume total de cargas globais, conforme dados da UNCTAD (2024). Em 2024, o transporte marítimo atingiu a marca de 12.292 milhões de toneladas movimentadas, representando um crescimento de 2,4% em relação ao ano anterior. Entretanto, este crescimento ocorreu em um cenário marcado por desafios operacionais inéditos e severos em rotas marítimas estratégicas, como os ataques no Mar Vermelho, que reduziram em 50% o tráfego pelo Canal de Suez, e a prolongada seca que limitou a capacidade do Canal do Panamá a apenas 3% do comércio global. Esses eventos forçaram maiores distâncias médias percorridas pelas mercadorias, atingindo 5.186 milhas por tonelada, o que impactou negativamente os custos logísticos e contribuiu para a elevação das emissões de carbono no setor.

Os portos, enquanto pontos estratégicos que conectam as cadeias de suprimentos globais, desempenham função crítica para o escoamento eficiente de importações e exportações, elementos indispensáveis para o funcionamento da economia mundial. Todavia, portos de grande porte enfrentam desafios operacionais significativos, tais como congestionamentos frequentes, longos tempos de espera dos navios para atracação, subutilização de berços de carga e custos operacionais elevados. Com a demanda marítima em expansão contínua, esses problemas tendem a se agravar, especialmente quando combinados com aspectos externos como alterações geopolíticas, a variabilidade climática e a pressão crescente por práticas ambientais sustentáveis. Esses fatores coletiva e intensamente impõem à gestão portuária a necessidade de soluções mais dinâmicas, adaptativas e inovadoras.

No contexto nacional, o sistema portuário brasileiro apresenta características peculiares que influenciam o seu desempenho operacional. Dentre elas destaca-se a alta concentração de cargas em poucos terminais, forte sazonalidade no fluxo de mercadorias e infraestrutura muitas vezes saturada, que provoca restrições à ampliação da capacidade portuária. Dentro deste cenário, o porto de Paranaguá, administrado pela Administração dos Portos de Paranaguá e Antonina (APPA), representa um dos principais corredores logísticos para a exportação de grãos do Sul do Brasil.

A operação da APPA é marcada por alta complexidade operacional, devido à diversidade de cargas movimentadas como contêineres, grânéis líquidos e sólidos, multiplicidade de operadores portuários e limitações físicas e logísticas próprias dos cais. Essas condições tornam recorrente um problema crítico na gestão portuária: o Problema de Alocação de Berços (PAB).

O PAB consiste em determinar a alocação da posição e do tempo de atracação dos navios nos berços disponíveis, observando uma série de parâmetros operacionais, tais como o tipo de carga transportada, a compatibilidade do calado da embarcação com o berço, o tempo

necessário para o serviço de carga e descarga, as janelas temporais para atracação estabelecidas e a disponibilidade dos equipamentos de movimentação, como os guindastes. Esta decisão impacta diretamente a eficiência operacional do porto, o tempo de espera das embarcações e os custos associados à operação.

A complexidade do PAB é acrescida pela natureza dinâmica e estocástica do ambiente portuário. Os tempos reais de chegada e serviço dos navios são altamente influenciados por diversas variáveis externas, incluindo condições meteorológicas imprevisíveis, atrasos logísticos, flutuações na demanda e restrições operacionais emergentes. Essas variabilidades tornam insuficientes as abordagens determinísticas tradicionais, que frequentemente não conseguem assegurar a eficiência necessária em contextos reais e voláteis.

Para lidar com essas dificuldades, trabalhos recentes têm experimentado diferentes abordagens para incorporar as incertezas inerentes e garantir soluções mais eficientes para o PAB. Destacam-se métodos clássicos de otimização, programação estocástica, metaheurísticas e técnicas de aprendizado de máquina.

O Aprendizado por Reforço (Reinforcement Learning - RL) é particularmente adequado para problemas dinâmicos, pois permite que o sistema evolua continuamente por meio de interações e aprendizado a partir de tentativas e erros, ajustando-se às condições do ambiente em tempo real. Por meio do mecanismo de recompensas, o algoritmo é capaz de guiar o comportamento e adaptar suas estratégias de alocação à variabilidade operacional, como alterações no tempo de chegada dos navios, flutuações meteorológicas e disponibilidade de recursos. Assim, busca-se melhor a previsão dos tempos de carregamento e descarregamento, além de otimizar o fluxo operacional dos terminais. Espera-se com essa abordagem alcançar maior precisão nas estimativas, reduzir custos de atracação e aperfeiçoar a utilização dos berços em condições reais e mutáveis.

Neste sentido, este trabalho propõe o desenvolvimento e a aplicação de uma abordagem por Aprendizado por Reforço para o PAB nos portos da APPA. Para isso, adota-se uma clusterização funcional capaz de capturar a heterogeneidade dos berços e das embarcações, permitindo segmentar o espaço de estados em grupos operacionais similares. O estudo avalia diferentes técnicas de agrupamento de berços, incluindo métodos estatísticos, como PCA, e abordagens evolutivas, como Algoritmos Genéticos, com o objetivo de reduzir a dimensionalidade do estado sem comprometer a operação do sistema portuário. Será também modelada a natureza estocástica das transições e formuladas funções de recompensa que reflitam objetivos operacionais prioritários, como a eficiência na ocupação dos berços e a redução dos tempos de espera dos navios.

Portanto, este estudo visa contribuir para uma solução adaptativa e replicável em ambientes portuários complexos, ampliando o conhecimento a respeito da aplicação do Aprendizado por Reforço em problemas logísticos reais e desafiadores como o PAB na APPA.

1.1 OBJETIVOS

O objetivo geral deste trabalho é desenvolver e avaliar uma abordagem baseada em Aprendizado por Reforço para tratar o Problema de Alocação de Berços nos portos sob administração da APPA, considerando as incertezas e particularidades inerentes à operação portuária, como a diversidade de tipos de carga movimentada, a sazonalidade na demanda, e as características do ambiente real.

Os objetivos específicos deste trabalho são:

- Aplicar técnicas de clusterização funcional para reduzir o espaço de estados e especializar regras de decisão para grupos de berços com características operacionais semelhantes;
- Implementar algoritmos de Aprendizado por Reforço, como o *Q-learning*, adaptados às especificidades e restrições operacionais da APPA;
- Realizar simulações computacionais, parametrizadas com dados reais do complexo portuário de Paranaguá (navios, berços e preferências), de modo a avaliar o desempenho e a eficiência através de um modelo discreto dinâmico;
- Comparar o desempenho da abordagem baseada em Aprendizado por Reforço com políticas tradicionais de alocação, como FIFO (First In, First Out) e PHT (Priority of Handling Time), utilizando métricas que contemplam tempo médio de espera, taxa de ocupação dos berços e robustez diante de diferentes cenários operacionais.

2 FORMULAÇÃO DO PROBLEMA

A Administração dos Portos de Paranaguá e Antonina (APPA) opera em um ambiente caracterizado por elevada complexidade operacional, resultado da coexistência de múltiplos berços multipropósito, restrições físicas heterogêneas e variabilidade temporal nos fluxos de embarcações. A eficiência na alocação de navios a esses berços é, portanto, determinante para o desempenho do sistema portuário, impactando diretamente os tempos de espera, a formação de filas e a utilização da infraestrutura disponível.

O Problema de Alocação de Berços (PAB) surge nesse contexto como um desafio central. A formulação adequada do PAB é essencial tanto para a análise de estratégias de decisão quanto para a avaliação de seus efeitos operacionais em cenários de alta carga e incerteza, como os observados na operação diária da APPA.

2.1 REVISÃO BIBLIOGRÁFICA

O Problema de Alocação de Berços (PAB) é um elemento fundamental na pesquisa em logística portuária, pois determina diretamente a eficiência do uso do cais, a produtividade do terminal e os custos operacionais da operação portuária (Cordeau *et al.*, 2005). O foco desta revisão é o PAB Discreto (PABD), amplamente estudado devido à sua aderência à realidade operacional de diversos portos. Assim, a literatura tem se consolidado ao redor de modelos matemáticos e de meta-heurísticas capazes de fornecer soluções robustas em horizontes compatíveis com a decisão operacional.

A organização conceitual mais difundida na literatura divide o PAB segundo dois eixos: (i) a dimensão espacial, que descreve o layout do cais como contínuo, discreto ou híbrido; e (ii) a dimensão temporal, distinguindo formulações estáticas ou dinâmicas (Barbosa *et al.*, 2016). Serão somente exploradas, dentro do PABD, as dimensões temporais, acrescidas do Processo Estocástico. A seleção dos trabalhos segue levantamentos sistemáticos apoiados sobretudo nos surveys de Barbosa *et al.* (2016) e Rodrigues e Agra (2022), que documentam a evolução metodológica e as principais estratégias de solução.

2.1.1 PAB DISCRETO ESTÁTICO (PABDS)

As formulações estáticas do PAB assumem que todos os navios são conhecidos antes do início da programação, o que viabiliza representações determinísticas relativamente compactas (Hansen; Oguz, 2003). Essa característica possibilita, em muitos casos, tratá-las como variantes de problemas de atribuição, solucionáveis em tempo polinomial (Cordeau *et al.*, 2005).

A consolidação dessa base teórica, inicia-se com o trabalho seminal de Imai, que formulou o PAB Discreto Estático (BAPDS) visando minimizar o tempo total de permanência das embarcações, representando o cais como posições discretas pré-definidas (Imai; Nagaiwa; Tat, 1997). Na década seguinte, avanços metodológicos ampliaram a fundamentação teórica do problema. Em 2003, Hansen e Oguz (2003) apresentaram uma formulação de Programação Inteira Mista (MIP), que se tornou referência por capturar, de maneira compacta, as restrições estruturais do PABDE. Pouco depois, Cordeau *et al.* (2005) reinterpretaram o PAB discreto como um Problema de Roteamento de Veículos Multi-Depósito com Janelas de Tempo (MDVRPTW), destacando sua natureza combinatória e aproximando-o de classes clássicas de problemas NP-difíceis.

Paralelamente, estudos sobre a equivalência entre modelos contínuos e discretos, como em (Imai; Sun *et al.*, 2005), reforçaram que formulações discretizadas eram suficientes para representar, com precisão prática, instâncias reais. Ao longo da década seguinte, pesquisas como as de Buhrkal *et al.* (2011) e Cereser *et al.* (2021) aprofundaram a análise comparativa entre modelos e evidenciaram a dificuldade crescente de resolução para instâncias de maior porte, mesmo em cenários totalmente estáticos.

Mais recentemente, o foco deslocou-se para aplicações em larga escala e cenários críticos. Yin *et al.* (2022) trataram explicitamente o PAB Discreto Estático sob restrições de maré e centenas de navios, propondo o Algoritmo Genético de Agrupamento de Variáveis Iterativo (IVGGA) como estratégia de decomposição eficiente. Em 2024, Hamdan *et al.* (2024) reforçaram a natureza NP-hard do PAB estático e discutiram o emprego de meta-heurísticas modernas, como o Harmony Search Algorithm, para enfrentar a complexidade crescente desses ambientes.

Em conjunto, esses avanços definiram o núcleo estrutural das formulações estáticas e estabeleceram as bases matemáticas, discretização, modelagem de janelas de tempo, decomposição e equivalência entre modelos, que posteriormente serviram de ponto de partida para a evolução do PAB em direção ao ambiente dinâmico e, mais recentemente, à otimização online baseada em aprendizado por reforço.

2.1.2 PAB DISCRETO DINÂMICO (PABDD)

A consideração das chegadas ao longo do horizonte de planejamento torna a programação de berços mais coerente com a operação real dos terminais portuários (Imai; Nishimura; Papadimitriou, 2001). A necessidade de lidar com decisões sequenciais e informações reveladas ao longo do tempo eleva significativamente a complexidade do problema, conferindo-lhe caráter NP-hard (Monaco; Sammarra, 2007). A evolução cronológica dos principais avanços mostra o esforço contínuo da literatura em aprimorar modelagens e métodos de solução.

A evolução cronológica desse campo inicia-se em 2001, quando foi proposta uma formulação dinâmica pioneira para o PABDD, resolvida por meio de Relaxação Lagrangiana e

método do subgradiente (Imai; Nishimura; Papadimitriou, 2001). O modelo foi expandido para incorporar prioridades de atendimento, o que exigiu a adoção de Algoritmos Genéticos, dada a natureza não linear introduzida pela nova função objetivo (Imai; Nishimura; Papadimitriou, 2003). Essa formulação estabeleceu as bases conceituais que nortearam os avanços subsequentes, sendo posteriormente refinada em (Monaco; Sammarra, 2007).

Uma mudança metodológica relevante ocorreu com a interpretação do PABDD como um Problema de Roteamento de Veículos com Múltiplos Depósitos e Janelas de Tempo (MDVRPTW), o que permitiu explorar heurísticas de Busca Tabu particularmente eficazes, como o T2S, capazes de alcançar desempenho comparável a métodos exatos truncados (Cordeau *et al.*, 2005). Pouco depois, uma reformulação mais compacta do PABDD foi apresentada com o intuito de reduzir o espaço de busca, novamente recorrendo a técnicas lagrangianas (Monaco; Sammarra, 2007).

O período seguinte é marcado pela consolidação e diversificação das meta-heurísticas aplicadas ao problema. Em 2008, a Busca em Vizinhança Variável demonstrou eficiência na minimização conjunta de custos de espera, manuseio e penalidades (Hansen; Oguz; Mladenović, 2008), enquanto uma abordagem de Simulated Annealing mostrou-se capaz de produzir soluções de alta qualidade com baixo tempo computacional (Mauri; De Oliveira; Lorena, 2008). Nesse mesmo ano, a integração entre o Problema de Alocação de Berços e a Atribuição de Guindastes ampliou o escopo de estudo, contemplando terminais multiusuários e sendo resolvida por meio de Algoritmos Genéticos (Imai; Chen *et al.*, 2008).

Os anos seguintes trouxeram novas estratégias híbridas e mecanismos de intensificação da busca. Técnicas como o Clustering Search (Oliveira; Mauri; Lorena, 2012) e abordagens híbridas baseadas em Busca Tabu (Lalla-Ruiz; Melián-Batista; Moreno-Vega, 2012) ampliaram as possibilidades de tratamento do PABDD, aprofundando o uso de estruturas de vizinhança e de mecanismos de diversificação controlada.

A partir disso, observa-se uma consolidação das meta-heurísticas como principal caminho para lidar com as crescentes dimensões e incertezas do problema. O estudo de Barbosa (2014) demonstrou que métodos baseados em Programação Inteira, embora eficientes para instâncias pequenas, perdem competitividade rapidamente à medida que o número de navios cresce. Nesse contexto, o Algoritmo Genético BRKGA destacou-se ao superar rotineiramente os solvers exatos, reforçando a tendência de priorizar abordagens meta-heurísticas em cenários dinâmicos. Outras contribuições relevantes desse período incluem a heurística Iterated Greedy proposta por Lin, Ying e Wan (2014) e a modelagem multi-agentes de Mnasri e Nasri (2014), que reinterpreta o PABD como um problema de máquinas paralelas, ampliando o escopo conceitual do problema.

A formulação linearizada de Programação Inteira Mista apresentada por Simrin e Diabat (2015) reforçou esse diagnóstico: apesar da sofisticação dos modelos exatos, sua escalabilidade seguia limitada, especialmente em cenários com dezenas de navios e berços. A meta-heurística baseada em Algoritmos Genéticos proposta pelos autores mostrou maior

robustez, reafirmando o papel dessas técnicas como alternativas práticas para instâncias reais e de grande porte.

Nos anos subsequentes, a literatura passou a incorporar mecanismos inspirados em inteligência coletiva e modelos multi-agentes. O trabalho de Prencipe e Marinelli (2020), ao comparar a Otimização por Colônia de Abelhas (BCO — *Bee Colony Optimization*), a Otimização por Colônia de Formigas (ACO — *Ant Colony Optimization*) e métodos exatos, consolidou a vantagem das meta-heurísticas de *swarm intelligence* em ambientes dinâmicos. Em paralelo, Mnasri e Alrashidi (2021) aprofundaram a abordagem baseada em Sistemas Multi-Agentes (MAS — *Multi-Agent Systems*), estruturada sobre negociação e coordenação distribuída, demonstrando ganhos de desempenho significativos frente ao Algoritmo Genético (GA) e à Busca Tabu, especialmente para instâncias complexas e sujeitas a múltiplas restrições operacionais.

Complementando essa evolução metodológica, surgiram contribuições que aumentaram a aderência dos modelos às condições reais de operação. Destaca-se o uso de Algoritmos Genéticos híbridos com Programação Dinâmica, capazes de representar restrições específicas de portos reais, como preferências de carga por berço e limitações geométricas, em aplicações práticas, como no estudo da APPA (Bacalhau; Casacio; Azevedo, 2021).

Mais recentemente, observa-se a transição para uma nova fase, marcada pelo uso crescente de Otimização Online e Aprendizado por Reforço. Estudos como o de Y. Dai, Z. Li e B. Wang (2023) introduziram variantes avançadas de RL profundo, como o Deep Double Q-Network, visando lidar com incertezas de chegada e setup de guindastes em tempo real. Em 2024, Wang, Li e Cao (2024) estenderam essa tendência ao demonstrar que modelos DQN podem superar heurísticas tradicionais, incluindo versões paralelas e híbridas do ACO, reduzindo substancialmente o tempo de espera dos navios. Este movimento evidencia a maturação da área rumo a abordagens adaptativas e capazes de aprender políticas diretamente das interações com o ambiente, inaugurando uma etapa de integração mais forte entre aprendizado online, simulação e otimização sob incerteza.

De forma geral, a trajetória da literatura revela um movimento contínuo em direção a modelos mais representativos e métodos cada vez mais refinados. A incorporação de elementos operacionais reais, somada ao uso crescente de métodos híbridos e técnicas de redução de complexidade, evidencia a maturidade alcançada pelo estudo do PABDD e sua capacidade de apoiar decisões críticas em ambientes portuários dinâmicos e altamente competitivos.

2.1.3 PAB DISCRETO ESTOCÁTICO (PABDE)

A realidade da operação portuária implica que os parâmetros de planejamento, como o tempo de chegada (AT) e o tempo de manuseio (HT), são frequentemente incertos devido a fatores como clima e falhas mecânicas (Zhen; Lee; Chew, 2011; Guo; Wang; Zheng, 2021; Rodrigues; Agra, 2022). As abordagens para lidar com a incerteza são classificadas como

proativas (P), que planejam a priori levando em conta a incerteza; reativas (R), que ajustam a programação após a ocorrência da interrupção; ou proativas/reativas (PR), que combinam uma solução de linha de base com ações de recurso ajustáveis (Rodrigues; Agra, 2022; Liu; Xiang; Zheng, 2020).

A Programação Estocástica (SP) assume conhecimento das distribuições de probabilidade. Zhen, Lee e Chew (2011) propõem um modelo de duas etapas (PR), balanceando custo base e recuperação. Ursavas e Zhu (2016) aplicam Programação Dinâmica Estocástica ao PABD, identificando políticas ótimas do tipo *threshold*.

A Otimização Robusta (RO), empregada quando faltam distribuições confiáveis, modela conjuntos de incerteza. Zhen e Chang (2012) apresentam um modelo biobjetivo que insere buffers para reforçar a robustez (Zhen; Chang, 2012). Liu, Xiang e Zheng (2020) propõem um modelo robusto de duas etapas (PR) com conjuntos orçamentados de incerteza, resultando em soluções menos conservadoras.

A seguir são destacados diversos trabalhos na área de aprendizado de máquina aplicados ao PAB, buscando justificar a aplicação do RL.

2.1.4 APRENDIZADO DE MÁQUINA APLICADO AO PAB

O emprego de técnicas de Aprendizado de Máquina (ML) na resolução do PAB tem se intensificado nas últimas décadas à medida que a operação portuária se tornou mais complexa e sujeita a ruído e incertezas. Enquanto os modelos clássicos baseados em programação matemática e heurísticas fornecem referências fundamentais para avaliação de qualidade e limites inferiores, eles frequentemente assumem premissas determinísticas ou simplificadoras que não se sustentam em cenários reais de operação (Rodrigues; Agra, 2022). Nesse contexto, abordagens *data-driven* permitem transformar incertezas, por exemplo, variações no *Estimated Time of Arrival* (ETA) e nos tempos de manuseio, em sinais passíveis de previsão e incorporação em regras de alocação mais resilientes (Rodrigues; Agra, 2022; Guo; Wang; Zheng, 2021).

A literatura aplicada ao PAB com ML organiza-se, de modo geral, em duas linhas principais (Rodrigues; Agra, 2022). A primeira envolve a previsão de parâmetros operacionais críticos, como ETA e HT (*handling time*), por meio de técnicas de regressão ou redes neurais, cujas estimativas são posteriormente incorporadas em modelos de otimização ou em *buffers* de robustez (Guo; Wang; Zheng, 2021; Kolley *et al.*, 2022). A segunda, mais promissora para decisões sequenciais em ambiente estocástico, corresponde às técnicas de RL, especialmente variantes de *Q-learning* e algoritmos de *Deep Q-Network*, capazes de aprender regras de alocação diretamente da interação com um simulador, sem a necessidade de modelar explicitamente as probabilidades de transição (Zeng; Yang; Hu, 2011; Cervellera *et al.*, 2021).

Trabalhos recentes demonstram a aplicabilidade e os ganhos potenciais do RL e de abordagens híbridas em problemas portuários próximos ao PAB. Zeng, Yang e Hu (2011) integraram simulação e RL para escalonamento de operações em terminais, evidenciando a

viabilidade da combinação simulação–aprendizado. Cervellera *et al.* (2021) investigaram a otimização de políticas para alocação de berços, destacando como a formulação por políticas (policy optimization) facilita replanejamentos em tempo real. Mais recentemente, estudos que aplicaram arquiteturas profundas, como *Deep Q-Network* (DQN) e suas variantes, por exemplo, Dueling DQN e Double DQN, mostraram ganhos em cenários com chegadas aleatórias de navios e tempos de configuração de guindastes, evidenciando maior robustez e adaptabilidade frente à aleatoriedade operacional (Dai, Yonggai; Li, Zongchen; Wang, Boyu, 2023; Zhou; Cao; Wang, 2024; Lv *et al.*, 2024). Além disso, iniciativas que combinam ML preditivo (para HT/ETA) com heurísticas de otimização (PSO, AG) apontam para uma via híbrida eficiente entre previsão e decisão (Guo; Wang; Zheng, 2021).

Ao examinar a literatura experimental e aplicada, emergem alguns padrões metodológicos e lacunas. Meta-heurísticas híbridas e métodos baseados em simulação continuam sendo referência para instâncias de grande escala, sobretudo quando o objetivo é incorporar restrições operacionais detalhadas, por exemplo, compatibilidades de carga e dimensões de navios. Por outro lado, *deep RL* tende a exigir volumes de dados e poder computacional substanciais para treinar agentes com boa generalização, e frequentemente carece de mecanismos explícitos para incorporar regras operacionais complexas sem engenharia adicional do espaço de estados ou da função de recompensa (Zhou; Cao; Wang, 2024; Lv *et al.*, 2024). Trabalhos que propuseram formulações robustas e distribucionalmente robustas (RO / DRO) mostram como controlar *trade-offs* entre desempenho médio e pior caso, oferecendo uma capacidade complementar ao RL para ambientes com incerteza limitada por informação histórica (Liu; Xiang; Zheng, 2020; Agra; Rodrigues, 2022).

Dessa análise decorre a motivação e o posicionamento do presente estudo. A opção por uma abordagem de RL, baseada em Q-learning tabular, por clusterização de berços, combina três vantagens pragmáticas: (i) permite incorporar, de forma direta e transparente, restrições operacionais reais (calado, comprimento, preferência de mercadoria) na definição de ações e penalidades; (ii) reduz o espaço de estados por meio de agregação (clusters), tornando o aprendizado computacionalmente exequível sem a necessidade de redes profundas; e (iii) conserva a capacidade de adaptação online do RL, aprendendo regras de alocação a partir de interação simulada que reproduz a incerteza observada empiricamente. Em síntese, enquanto a literatura mostra avanços relevantes em predição, heurística e RL profunda para o PAB, a combinação proposta, Q-learning tabular aplicado ao contexto operacional da APPA, constitui uma contribuição original ao traduzir os benefícios do RL para um porto multipropósito com forte sazonalidade, onde a heterogeneidade de berços e a necessidade de decisões em tempo quase real impõem requisitos específicos pouco contemplados em trabalhos anteriores.

Por fim, a revisão aqui sumarizada evidencia que, embora existam estudos que aplicam RL ao PAB em ambientes controlados ou sintéticos, há escassez de trabalhos que integrem: (a) estrutura operacional real de um complexo portuário multipropósito; (b) redução de dimensionalidade via clusterização orientada por restrições; e (c) validação em instâncias

geradas a partir de dados históricos de operação, exatamente o conjunto de características que diferencia e justifica a relevância deste trabalho para o caso da APPA.

2.2 ASSOCIAÇÃO DE PORTOS DE PARANAGUÁ E ANTONINA (APPA)

A APPA coordena um dos principais complexos portuários do Brasil, cuja operação combina alto volume de cargas, diversidade logística e forte variabilidade temporal. Com 24 berços distribuídos entre Paranaguá e Antonina, a APPA movimenta dezenas de milhões de toneladas por ano, atendendo principalmente grãos, fertilizantes, combustíveis, líquidos, carga geral e contêineres. O Porto de Paranaguá, responsável pela maior parte dessas operações, figura entre os portos públicos de maior relevância no país, com fluxos que alcançam mais de 60 milhões de toneladas em anos recentes, um aumento de 6,2%.

Sua área de influência da APPA ultrapassa o estado do Paraná, conectando produtoras do Mato Grosso, Santa Catarina e parte de São Paulo a diversos destinos internacionais, com destaque para China, Holanda e Coreia do Sul. Essa escala operacional reforça a importância de estratégias eficientes de alocação de navios, especialmente em períodos críticos como a safra agrícola.

Os berços apresentam características específicas de comprimento, profundidade e compatibilidade operacional, impondo restrições diretas ao PAB. Cada embarcação pode ser alocada apenas a berços compatíveis com suas dimensões físicas e tipo de carga, o que restringe o conjunto viável de decisões.

A organização espacial dos berços, ilustrada na Figura 1, evidencia a segmentação funcional entre os portos de Paranaguá e Antonina, refletindo especializações operacionais que influenciam diretamente o processo de alocação.

Entre suas características operacionais destacam-se:

- sazonalidade intensa, que aumenta filas de espera na safra;
- heterogeneidade estrutural, com berços especializados e multipropósito;
- diversidade de cargas (granel sólido, granel líquido, carga geral, contêineres);
- restrições físicas rígidas (calado, comprimento, calado dinâmico, largura);
- infraestrutura próxima da capacidade, agravando conflitos por recursos;
- exigência de priorização de cargas estratégicas, como fertilizantes e combustíveis;
- variação operacional elevada ao longo do dia.

Figura 1 – Organização dos berços de atracação na APPA



Fonte: Portos do Paraná (2024).

A Tabela 1 resume as características técnicas dos berços, diferenciando profundidade, comprimento e preferência operacional. Essas informações são essenciais para a formulação do PAB, pois definem o conjunto viável de alocação de navios.

Tabela 1 – Instalações portuárias da APPA

ID	Comprimento (m)	Profundidade (m)	Mercadorias preferenciais
Granéis Líquidos			
141	210	12.1	Combustíveis
142	190	10.6	Combustíveis
143	220	11.9	Combustíveis, Óleo Alimentício
144	220	8.0	Óleo Alimentício, Combustíveis
Granéis Sólidos			
200	190	12.5	Fertilizantes
200A	235	9.2	Fertilizantes
201	225	11.8	Fertilizantes, Grãos, Farelos

Continua na próxima página

ID	Comprimento (m)	Profundidade (m)	Mercadorias preferenciais
204	190	11.8	Açúcar, Grãos
206	225	10.6	Grãos
208	200	9.3	Sal Marinho, Fertilizantes
209	241	12.7	Fertilizantes
211	200	12.7	Fertilizantes
212	251	13.0	Farelos, Grãos
213	253	13.0	Farelos, Grãos
214	259	13.0	Farelos, Grãos
Carga Geral			
202	200	11.3	Açúcar, Veículos
205	160	11.0	Açúcar, Passageiros
Contêineres			
215	336	13.0	Veículos, Contêineres
216	336	13.0	Contêineres
217	336	13.0	Contêineres
218	200	10.0	Contêineres
219	200	10.0	Veículos
Multipropósitos			
113	160	9.5	Açúcar, Passageiros
114	200	9.5	Açúcar, Grãos

Fonte: elaborado pelo próprio autor (2025)

Essas características tornam a APPA um ambiente particularmente adequado para o estudo do PAB, uma vez que pequenas variações nas decisões de alocação podem resultar em impactos significativos nos níveis de congestionamento, nos tempos de espera e na eficiência global do sistema.

2.3 PROBLEMA DE ALOCAÇÃO DE BERÇOS (PAB)

O Problema de Alocação de Berços consiste em determinar, para cada navio, o berço ao qual será alocado e o instante de início de sua operação. Na literatura, o PAB pode ser classificado segundo diferentes dimensões, das quais se destacam as dimensões espacial e temporal.

- **Dimensão espacial**

- **Discreto:** os berços são posições fixas previamente definidas.
- **Contínuo:** a posição é escolhida ao longo de um cais modelado como segmento contínuo.
- **Híbrido:** parte da infraestrutura é fixa, parte é contínua.
- **Aplicação na APPA:** como os portos possuem berços individualizados e com características distintas, o problema se enquadra naturalmente no modelo discreto.

▪ Dimensão temporal

- **Estático:** todas as chegadas são conhecidas antecipadamente.
- **Dinâmico:** os navios chegam ao longo do tempo.
- **Estocástico:** incorpora incertezas de chegada e operação.

A operação real da APPA, marcada por atrasos, clima e variação na disponibilidade dos navios, configura claramente um ambiente dinâmico. Portanto a APPA fornece o ambiente ideal para o PAB analisado neste trabalho por três motivos centrais:

- Estrutura discreta: As posições de atracação são fixas e pré-determinadas, compatíveis com a formulação do PAB discreto.
- Operação dinâmica: Os navios chegam continuamente, sujeitos a atrasos, sazonalidade e variações operacionais.
- Heterogeneidade e múltiplas preferências: Berços multipropósito, diferenças de calado e cargas com múltiplas possibilidades de atracação tornam a decisão não trivial.

Embora o modelo a ser apresentado busque representar fielmente a lógica operacional, algumas situações reais foram excluídas por não integrarem o escopo analítico, como a retirada de navios da fila ou negociações relacionadas à sobreestadia (*demurrage*).

2.3.1 FORMULAÇÃO MATEMÁTICA DO PAB DISCRETO DINÂMICO

O Problema de Alocação de Berços (PAB) pode ser abordado de maneira discreta, considerando os berços como unidades de tamanho fixo, o que representa uma adaptação prática para ambientes portuários como o da APPA. Essa abordagem é inspirada no modelo proposto por Bacalhau (2021), que não incorpora penalidades ou preferências específicas de mercadorias, tratando o problema de forma generalizada e focada na eficiência de alocação em berços multipropósito.

ÍNDICES E CONJUNTOS

$i \in B$ índice dos berços disponíveis no porto.

$j \in N$ índice dos navios que devem ser alocados.

$j' \in N \setminus \{j\}$ índice de outro navio distinto de j , usado para definir ordem de atendimento.

PARÂMETROS

A_j instante de chegada do navio j ao sistema portuário.

M_j instante de início do atendimento (atracação) do navio j .

S_{ij} tempo de serviço do navio j no berço i .

d_i profundidade disponível no berço i .

h_i altura máxima permitida no berço i .

l_i comprimento máximo permitido no berço i .

d_j, h_j, l_j profundidade, altura e comprimento requeridos pelo navio j .

$d_{min}, h_{min}, l_{min}$ margens mínimas de segurança para profundidade, altura e comprimento.

VARIÁVEIS DE DECISÃO

x_{ij} variável binária que indica a alocação do navio j ao berço i :

- $x_{ij} = 1$ se o navio j é alocado ao berço i ;
- $x_{ij} = 0$ caso contrário.

$y_{jj'}$ variável binária que representa a precedência entre navios alocados ao mesmo berço:

- $y_{jj'} = 1$ se o navio j é atendido antes do navio j' ;
- $y_{jj'} = 0$ caso contrário.

DOMÍNIO DAS VARIÁVEIS

$$\begin{aligned} x_{ij} &\in \{0,1\}, & \forall i \in B, \forall j \in N \\ y_{jj'} &\in \{0,1\}, & \forall j \in N, \forall j' \in N \setminus \{j\} \end{aligned}$$

FORMULAÇÃO MATEMÁTICA

A formulação matemática do PAB discreto dinâmico sugere que seja calculado, para cada navio $j \in N$ e berço $i \in B$:

$$Z = \sum_{i \in B} \sum_{j \in N} [(M_j - A_j) + S_{ij}] x_{ij} \quad (2.1)$$

sujeito às seguintes restrições:

$$\sum_{i \in B} x_{ij} = 1, \quad \forall j \in N \quad (2.2)$$

$$\sum_{i \in B} [d_i - (d_j + d_{min})] x_{ij} \geq 0, \quad \forall j \in N \quad (2.3)$$

$$\sum_{i \in B} [h_i - (h_j + h_{min})] x_{ij} \geq 0, \quad \forall j \in N \quad (2.4)$$

$$\sum_{i \in B} [l_i - (l_j + l_{min})] x_{ij} \geq 0, \quad \forall j \in N \quad (2.5)$$

$$\left[M_{j'} - \left(\sum_{i \in B} S_{ij} x_{ij} + M_j \right) \right] y_{jj'} \geq 0, \quad \forall j \in N, \forall j' \in N \setminus \{j\} \quad (2.6)$$

Neste modelo:

- A expressão (2.1) representa uma métrica de desempenho agregada, que contabiliza o tempo de espera e o tempo de serviço dos navios no sistema, sendo utilizada exclusivamente para comparação entre políticas.
- A restrição (2.2) assegura que cada navio seja alocado a exatamente um berço.
- As restrições (2.3)–(2.5) garantem a viabilidade física e operacional das alocações.
- A restrição (2.6) estabelece a coerência temporal do atendimento entre navios alocados ao mesmo berço.

Dessa forma, o modelo matemático não é resolvido como um problema de otimização, sendo empregado como uma formulação de referência que estrutura o processo de simulação, garante o atendimento às restrições operacionais do sistema portuário e viabiliza o cálculo consistente das métricas de desempenho analisadas nos experimentos.

3 APRENDIZADO POR REFORÇO

O estudo de problemas operacionais que evoluem no tempo, sujeitos a incertezas e a informações parcialmente reveladas, frequentemente exige um arcabouço matemático capaz de representar decisões tomadas de forma iterativa. Nesses cenários, os *Processos de Decisão Sequencial* (SDP) fornecem uma estrutura formal para modelar sistemas nos quais cada decisão influencia simultaneamente o desempenho imediato e o estado futuro do sistema (Bertsekas, 2012). A formulação em termos de estados, ações e dinâmicas de transição permite capturar a natureza encadeada das decisões, característica central de diversos problemas logísticos complexos, incluindo operações portuárias, despacho de recursos e planejamento reativo em ambientes com variabilidade operacional.

Nesse contexto, métodos de Aprendizado por Reforço (RL) surgem como alternativas particularmente eficazes quando as probabilidades de transição ou distribuições estocásticas associadas ao sistema não são conhecidas de forma explícita. Entre esses métodos, o RL destaca-se por sua capacidade de aproximar valores ótimos de decisão apenas por meio de interações simuladas com o ambiente, dispensando a modelagem analítica das dinâmicas subjacentes (Watkins, 1992; Sutton; Barto, 1998). Em termos computacionais, o método atualiza estimativas numéricas para cada par estado-ação com base em observações sucessivas, ajustando tais estimativas para aproximar o valor ótimo associado ao processo decisório sequencial. O mecanismo de atualização fundamenta-se na diferença temporal (*temporal-difference*), que combina observações imediatas com estimativas futuras, permitindo aprendizado incremental, estável e compatível com ambientes não estacionários.

A utilidade prática dessa abordagem tem sido amplamente demonstrada em domínios onde a dinâmica do sistema é complexa, ruidosa ou de difícil representação matemática. Em particular, operações portuárias apresentam características que se ajustam naturalmente a esse tipo de modelagem: chegadas irregulares de navios, tempos de operação incertos, interferências climáticas e necessidade de decisão em tempo quase real. Estudos recentes têm explorado justamente essa convergência, utilizando Q-learning para aproximar soluções de problemas de alocação, escalonamento ou despacho em condições sujeitas a variabilidade operacional (Cervellera *et al.*, 2021; Dai, Yonggai; Li, Zongchen; Wang, Boyu, 2023). A ausência de necessidade de um modelo probabilístico estruturado torna o método especialmente atrativo para problemas cuja incerteza não pode ser adequadamente capturada por distribuições clássicas ou por modelos paramétricos confiáveis.

No contexto deste trabalho, a adoção de Aprendizado por Reforço decorre de sua capacidade de lidar com problemas onde a decisão ótima depende da interação entre múltiplas etapas interligadas. A natureza sequencial do PAB dinâmico, combinada à incerteza operacional que rege o fluxo de navios e a variabilidade nos tempos de atendimento, enquadra-se de maneira

direta na formulação de um SDP. Assim, o método é empregado como um estimador iterativo dos valores associados às decisões de alocação em diferentes estados do sistema, construindo o conhecimento necessário para a escolha de ações que minimizem efeitos cumulativos, como espera, desalinhamentos operacionais ou configurações subótimas de utilização do cais.

Dessa forma, *Q-learning* funciona como um conector entre a estrutura teórica dos Processos de Decisão Sequencial e a necessidade prática de soluções robustas para problemas de natureza dinâmica e estocástica. O método oferece uma alternativa computacionalmente viável para representação e busca de valores ótimos ao longo do tempo, mantendo coerência com a estrutura matemática do problema e adequação às particularidades operacionais que motivam a análise desenvolvida nesta dissertação.

3.1 PROCESSO DE DECISÃO SEQUENCIAL

Para a aplicação do *Q-learning*, modela-se um Processo de Decisão Sequencial (SDP), permitindo representar a dinâmica temporal e as restrições operacionais do ambiente portuário. Essa abordagem é especialmente adequada para cenários em que decisões devem ser tomadas em etapas sucessivas, considerando o impacto de cada ação sobre o estado futuro do sistema.

3.1.1 PARÂMETROS DO APRENDIZADO POR REFORÇO

Seja S o conjunto de estados e A o conjunto de ações disponíveis ao agente. O valor $|A|$ representa a cardinalidade do espaço de ações.

O algoritmo de *Q-learning* utiliza os seguintes parâmetros:

- $\alpha \in (0,1]$: taxa de aprendizado;
- $\gamma \in [0,1]$: fator de desconto;
- $\epsilon \in [0,1]$: taxa de exploração da política ϵ -greedy.

A seguir, são definidos os principais elementos que compõem o SDP:

- **Espaço de Estados (S):** Cada estado representa uma configuração do sistema portuário em um dado instante, incluindo informações como a fila de navios aguardando atracação, a ocupação atual dos berços, o tipo de carga transportada, e as restrições operacionais vigentes.

Cada estado é representado por:

$$s^t = [s_1^t, s_2^t, \dots, s_b^t] \quad (3.1)$$

onde b é o número de berços e s_j^t é o número de horas restantes para a finalização do serviço no berço j no instante t . Cada estado $s \in S$ captura as condições operacionais do sistema em um determinado momento.

- **Espaço de Ações (A):** As ações correspondem às decisões de alocação de navios aos berços disponíveis. Cada ação considera fatores como compatibilidade de carga, tempo estimado de operação, e preferências logísticas.

Cada ação possível em um instante de decisão t é representada por:

$$a_k^t = (b_j, c_i, d) \quad \text{com} \quad a_k^t \in A \quad (3.2)$$

onde b_j é o identificador de um berço j disponível, $c_i \in \{\text{carga 1, carga 2, } \dots \text{ carga } m\}$ representa o tipo de carga m do navio i , $d \in \{0, 1\}$ indica o atraso, sendo $d = 0$ a alocação sem atraso e $d = 1$ a alocação com atraso, e o índice k representa a identificação única de uma ação no conjunto A , em um determinado instante t . A ação de não realizar nenhuma alocação é representada por

$$a_{\text{zero}} = (0, 0, 0),$$

e não gera recompensa associada.

O conjunto A de ações possíveis em cada instante t é condicionado pelas restrições operacionais de compatibilidade entre o navio e os berços (dimensões, tipo de carga) e a disponibilidade atual dos berços, conforme o estado s^t .

- **Função de Recompensa (R):** A recompensa quantifica o desempenho da ação tomada em determinado estado. Pode ser definida com base em métricas como tempo de espera minimizado, eficiência na utilização dos berços, ou atendimento às preferências de carga.

Ela é definida por:

$$R(a_k^t, s^t) = \begin{cases} -1, & \text{se a ação resultar em violação} \\ & \text{de restrição de ocupação do berço;} \\ 0, & \text{se } a_k^t = (0, 0, 0); \\ 2 \cdot \sum_{j=1}^b s_j^t, & \text{se a alocação for feita com atraso;} \\ \sum_{j=1}^b s_j^t, & \text{caso contrário.} \end{cases} \quad (3.3)$$

A função proposta visa incentivar alocações que aumentam a utilização dos berços (refletida pela soma dos tempos de ocupação), penaliza decisões inválidas com recompensa negativa e atribui um peso maior às ações realizadas com atraso.

- **Função de Transição (T):** Representa a probabilidade de transição entre estados após a execução de uma ação. No contexto portuário modelado, essa transição inclui a evolução estocástica dos tempos restantes de atendimento nos berços, sendo discretizados em múltiplos de três horas para reduzir a complexidade do espaço de estados. A cada passo

de tempo (1 hora), com probabilidade $p = 0,9$, o tempo restante de serviço de cada berço ocupado é reduzido aleatoriamente entre 1 e 3 horas, sendo o novo estado ajustado conforme a discretização adotada. Embora essa função possa ser desconhecida ou difícil de modelar analiticamente, algoritmos *model-free* como o *Q-learning* permitem aprender estratégias eficazes diretamente da interação com o ambiente, capturando essa dinâmica probabilística de forma implícita.

A dinâmica de transição é formalizada pela seguinte equação:

$$s_j^{t+1} = \begin{cases} \left\lceil \frac{(s_j^t \cdot 3 - \delta)}{3} \right\rceil, & \text{com probabilidade } p, \\ s_j^t, & \text{caso contrário,} \end{cases} \quad (3.4)$$

onde s_j^t é o estado do berço j no instante t , $\delta \in \{1,2,3\}$ representa a redução estocástica em horas, e s_j^{t+1} é o novo estado no instante seguinte. Esse mecanismo permite representar a variabilidade das operações portuárias, ao mesmo tempo em que mantém a complexidade computacional controlada por meio da discretização.

- **Horizonte de Decisão:** O problema pode ser formulado com horizonte finito (por exemplo, um ciclo operacional diário) ou infinito, dependendo da estratégia de otimização adotada.

O estudo considera o cenário do Porto de Paranaguá (APPA), caracterizado por: (i) Cais multipropósito com berços heterogêneos. (ii) Chegada dinâmica de embarcações, sujeita a incertezas. (iii) Restrições de calado, comprimento e tipo de carga.

O PAB consiste em alocar um conjunto de navios $N = \{1, 2, \dots, n\}$ a um conjunto de berços $B = \{1, 2, \dots, b\}$ ao longo do horizonte de planejamento, minimizando métricas como o tempo total de espera e a permanência no porto. A chegada dos navios segue um processo dinâmico, com eventos estocásticos. Para fins de modelagem, considera-se que rebocadores e guindastes estão sempre disponíveis, não há cancelamento de atracação após a programação e a janela contratual, bem como as preferências comerciais, não foram incluídas.

3.2 APRENDIZADO POR REFORÇO ADAPTADO

Dando continuidade às regras de decisão apresentadas, esta seção detalha a abordagem baseada em *Q-learning*, adaptada para o contexto portuário da APPA. O método proposto combina técnicas de clusterização operacional, treinamento modular de tabelas Q e simulação estocástica baseada em dados reais, visando a otimizar a alocação dinâmica de navios aos berços disponíveis.

A adoção da clusterização nesta etapa decorre diretamente do comportamento explosivo do espaço de estados observado no PAB dinâmico da APPA. Em particular, verificou-se que a

representação integral dos 24 berços, cada um com múltiplos níveis discretizados de ocupação, produz uma quantidade de estados tão elevada que inviabiliza a construção e o treinamento de uma única tabela Q global com granularidade adequada. Essa constatação motivou a decomposição do problema em grupos de berços estruturalmente semelhantes, permitindo que o processo de aprendizado opere sobre subconjuntos mais homogêneos e computacionalmente manejáveis.

Essa estratégia de agrupamento reduz a dimensionalidade efetiva do problema, preservando as relações operacionais relevantes, tais como tipos de carga atendidos, padrões de atendimento e comportamento típico de filas, ao mesmo tempo em que evita a *maldição da dimensionalidade* discutida posteriormente. Dessa forma, cada cluster se torna um módulo independente de treinamento, com sua própria tabela Q , possibilitando convergência mais rápida, redução do custo computacional e manutenção de fidelidade ao processo decisório real, especialmente em um porto multipropósito de alta sazonalidade como a APPA.

3.2.1 ANÁLISE DE COMPLEXIDADE

Foi realizada uma análise de complexidade do espaço de estados associado à alocação de navios nos berços da APPA. Essa etapa teve como objetivo demonstrar a inviabilidade de aplicação de métodos exatos.

O problema envolve 24 berços operacionais (Tabela 1), cada um com possíveis tempos de espera discretizados entre 0 e 15 horas. Considerando 16 níveis discretos por berço, o total de combinações possíveis de estados seria da ordem de 16^{24} , representando aproximadamente $3,0 \times 10^{28}$ soluções.

Essa explosão combinatória é uma manifestação da *maldição da dimensionalidade* (do inglês, *curse of dimensionality*), conceito introduzido por Bellman ((1957)), que descreve o crescimento exponencial do espaço de estados com o aumento do número de variáveis de decisão, tornando inviável a aplicação de métodos exatos. Em problemas de decisão sequencial como o presente, essa complexidade compromete diretamente a viabilidade do treinamento e da convergência de algoritmos por RL.

Diante dessa explosão combinatória, procedeu-se à redução da dimensionalidade por meio de duas estratégias complementares: (i) a clusterização dos berços em grupos funcionalmente similares, os 24 berços foram agrupados entre 5 e 8 *clusters*. Por exemplo, o *cluster* 5, que representa um subconjunto com 5 agrupamentos, ainda apresentava complexidade significativa. Mesmo com discretização de 16 níveis, um *cluster* com 7 berços resultaria em $16^7 = 268.435.456$ possíveis estados; (ii) adota-se uma discretização do tempo de serviço em seis níveis: nível 0 (sem espera) e cinco níveis adicionais, representando faixas de 3 horas cada (1–3h, 4–6h, 7–9h, 10–12h e 13–15h). Essa escolha reduz o número de estados por berço de 16 para 6, resultando em $6^7 = 279.936$ combinações, porém, um valor ainda elevado, mas manejável para abordagens em RL.

A clusterização é especialmente importante no contexto do problema proposto, em que muitos berços compartilham características operacionais, como o tipo de carga que atendem. Ao agrupar berços semelhantes em *clusters*, o RL pode operar sobre uma representação abstrata, sem comprometer a fidelidade do processo decisório.

3.2.2 CLUSTERIZAÇÃO DOS BERÇOS

A primeira etapa da abordagem proposta consiste na segmentação dos berços do porto em conjuntos operacionais homogêneos, com o objetivo de reduzir a complexidade do espaço de decisão do Problema de Alocação de Berços. A clusterização é conduzida com base nas características operacionais dos berços, em especial na distribuição dos tipos de carga movimentados, uma vez que essa variável condiciona diretamente restrições físicas, tempos de operação e compatibilidades de atracação.

Ao agrupar berços com perfis operacionais semelhantes, busca-se criar subconjuntos mais coerentes, nos quais as decisões de alocação possam ser analisadas de forma especializada, reduzindo interferências entre berços estruturalmente distintos e facilitando a avaliação de políticas de decisão.

A definição manual dos agrupamentos, embora possível em sistemas de pequena escala, mostrou-se inadequada no contexto analisado. A APPA apresenta um conjunto elevado de berços com perfis operacionais parcialmente sobrepostos, nos quais a compatibilidade de cargas, profundidades e padrões de uso varia ao longo do tempo. Uma clusterização definida a priori introduziria subjetividade na segmentação e dificultaria a reprodutibilidade dos resultados, além de não capturar mudanças estruturais observadas nos dados históricos.

O uso de métodos baseados em dados permite que os agrupamentos sejam determinados a partir das características reais de operação, assegurando consistência analítica, reprodutibilidade e menor dependência de decisões arbitrárias. Dessa forma, a clusterização automatizada não substitui o conhecimento operacional, mas o sistematiza, fornecendo uma base objetiva para a avaliação comparativa das estratégias de alocação.

Foram investigadas duas estratégias distintas de agrupamento. A primeira utiliza a Análise de Componentes Principais (*Principal Components Analysis – PCA*), aplicada como uma ferramenta exploratória de redução de dimensionalidade. O PCA permite identificar combinações lineares dominantes nas variáveis associadas à movimentação de cargas, evidenciando padrões latentes de similaridade entre os berços e possibilitando sua visualização e agrupamento em um espaço de menor dimensão. Essa abordagem é particularmente adequada para avaliar se a segmentação operacional emerge naturalmente dos dados históricos, sem a imposição de critérios arbitrários.

A segunda estratégia baseia-se em um Algoritmo Genético (AG), formulado para tratar explicitamente o problema de clusterização como uma tarefa de otimização combinatória. Nesse caso, o objetivo é encontrar uma partição dos berços que maximize a homogeneidade interna dos

grupos e, simultaneamente, preserve diferenças operacionais relevantes entre clusters distintos. O uso de um AG justifica-se pela natureza não convexa e discreta do problema, na qual o número de possíveis partições cresce rapidamente com o número de berços, tornando inviável a enumeração exaustiva ou o uso de métodos determinísticos clássicos.

Enquanto o PCA fornece uma referência analítica e interpretável da estrutura dos dados, o AG oferece maior flexibilidade para incorporar critérios operacionais específicos e restrições adicionais, permitindo avaliar se uma clusterização orientada por desempenho operacional produz resultados superiores. A comparação entre ambas as abordagens possibilita analisar o trade-off entre interpretabilidade e capacidade de otimização no processo de segmentação dos berços.

Para a avaliação de ambas as estratégias foram utilizados dados históricos da Administração dos Portos de Paranaguá e Antonina (APPA), contemplando a distribuição de cargas por berço ao longo de diferentes períodos operacionais. Esses dados permitem capturar padrões recorrentes de utilização e fornecem base empírica para a validação das estruturas de agrupamento obtidas.

3.2.3 ANÁLISE DE COMPONENTES PRINCIPAIS (PCA)

Para explorar alternativas de redução dimensional e identificar padrões operacionais entre os berços da APPA, foi desenvolvida uma avaliação preliminar baseada na aplicação conjunta de Análise de Componentes Principais (PCA) e do algoritmo de clusterização k-means. O objetivo foi verificar se variáveis de movimentação de cargas e atributos físicos dos berços permitiriam a formação de grupos naturalmente distintos, capazes de auxiliar na redução do espaço de estados utilizado posteriormente pelo método de *Q-learning*.

Os dados foram inicialmente organizados em uma matriz berço-atributo, na qual cada linha representa um berço e cada coluna indica a ocorrência ou capacidade de operação de um determinado tipo de carga. Essa matriz foi construída por meio de codificação binária (*one-hot encoding*), resultando em um espaço de alta dimensionalidade. Antes da aplicação do PCA, todas as variáveis foram normalizadas por padronização do tipo *z-score*, de forma a garantir média zero e variância unitária, evitando que diferenças de escala influenciassem a análise.

A PCA foi utilizada para projetar o conjunto multivariado de características em um espaço de menor dimensionalidade, preservando a maior parcela possível da variabilidade observada. Formalmente, essa projeção é obtida a partir da decomposição da matriz de covariância dos dados normalizados, sendo os componentes principais definidos como combinações lineares das variáveis originais associadas aos maiores autovalores. Na aplicação realizada, foram retidos os dois primeiros componentes principais, que concentraram a maior parcela da variância total dos dados e permitiram a representação bidimensional dos berços. Em seguida, o algoritmo k-means foi aplicado sobre os componentes principais, buscando identificar partições coerentes no espaço reduzido.

A combinação dos métodos resultou na identificação de três agrupamentos predominantes, que corresponderam, de forma geral, a berços especializados em granéis líquidos, granéis sólidos e berços multipropósito. A definição do número de clusters foi avaliada por meio de análises exploratórias complementares, como inspeção visual do espaço dos componentes principais e métricas clássicas de validação, incluindo o método do cotovelo e o índice de silhueta.

Embora o procedimento tenha produzido redução relevante da variância intra-grupo, verificou-se uma limitação importante: berços multipropósito, por operarem múltiplos tipos de carga ao longo do ano, apresentaram sobreposição significativa entre os clusters, dificultando a obtenção de fronteiras claras e operacionalmente úteis. Essa sobreposição sugere que características estáticas, como dimensões físicas ou tipos de carga históricos, não são suficientes para representar adequadamente as diferenças dinâmicas do processo de atracação, especialmente em um porto com alta sazonalidade como o da APPA.

Assim, embora o método PCA + k-means tenha oferecido uma visão inicial da estrutura latente dos dados, sua capacidade de representar a dinâmica operacional mostrou-se limitada. Por esse motivo, optou-se por empregar uma abordagem de clusterização baseada diretamente em atributos operacionais relevantes ao processo decisório, tais como padrões de atendimento, tempos médios de operação e perfis de demanda, permitindo a construção de agrupamentos mais alinhados ao comportamento real dos berços e, conseqüentemente, mais adequados ao treinamento modular do algoritmo de Aprendizado por Reforço.

Todos os dados e análises mencionados são apresentados detalhadamente nos estudos de casos.

3.2.4 ALGORITMO GENÉTICO (AG)

A segunda etapa da estratégia de redução dimensional consiste na definição automática dos agrupamentos de berços, realizada por meio de um Algoritmo Genético (AG). Diferentemente da técnica de PCA, o AG permite incorporar diretamente critérios operacionais e restrições estruturais do problema, otimizando a formação dos grupos de forma orientada à aplicação em Aprendizado por Reforço.

Em particular, o AG foi desenvolvido para particionar os conjuntos de mercadorias em um número pré-definido de clusters, entre $K = 5$ e $K = 8$, refletindo o intervalo avaliado na análise de complexidade (Seção 3.2.1). Cada cromossomo representa uma atribuição completa de mercadorias a clusters, e a aptidão (*fitness*) de cada solução é calculada com base na qualidade do agrupamento resultante em termos de distribuição dos berços.

Codificação e solução representada. Cada cromossomo é um vetor de inteiros, no qual cada posição corresponde a uma mercadoria, e o valor inteiro indica o cluster ao qual ela foi atribuída. A partir dessa representação, o conjunto de berços é reconstruído, já que cada mercadoria está associada a um subconjunto específico de berços reais.

Função de fitness. A função de aptidão foi construída para refletir diretamente os requisitos operacionais do RL. Ela busca:

1. maximizar o número total de berços efetivamente cobertos pelos clusters formados;
2. evitar clusters demasiadamente grandes, penalizando soluções com concentração excessiva de berços em um único grupo;
3. garantir que o número de clusters do cromossomo seja exatamente o número desejado, descartando automaticamente soluções inválidas.

Formalmente, o valor de *fitness* de um cromossomo c é dado por:

$$\text{fitness}(c) = \sum_{i=1}^K |B_i| - \sum_{i=1}^K |B_i|^2,$$

onde B_i é o conjunto de berços associados ao cluster i .

O primeiro termo, $\sum_{i=1}^K |B_i|$, incentiva a utilização ampla dos clusters disponíveis, favorecendo soluções nas quais os berços são distribuídos de forma abrangente pelo sistema e desencorajando a formação de clusters vazios ou pouco representativos.

O segundo termo, $\sum_{i=1}^K |B_i|^2$, atua como um mecanismo de regularização, penalizando de maneira crescente clusters excessivamente grandes. Como o crescimento quadrático amplifica diferenças de cardinalidade, esse termo induz a busca por soluções mais balanceadas, evitando a concentração excessiva de berços em poucos clusters.

A combinação desses dois termos estabelece um compromisso entre cobertura e equilíbrio, produzindo partições que preservam diversidade estrutural e, ao mesmo tempo, mantêm tamanhos de clusters relativamente homogêneos. Tal característica é fundamental para o Aprendizado por Reforço subsequente, pois reduz a assimetria do espaço de estados e contribui para maior estabilidade e eficiência no processo de treinamento.

Operadores do AG. O algoritmo utiliza:

- **Seleção por torneio** de tamanho 3;
- **Crossover de um ponto**, aplicado com probabilidade de 0,9;
- **Mutação independente por gene**, com taxa de 0,10;
- **Substituição geracional elitista**, mantendo os dois melhores indivíduos entre pais e filhos.

Execução para múltiplos valores de K . O algoritmo foi executado para $K = 5, 6, 7, 8$, permitindo avaliar configurações distintas do espaço reduzido utilizado pelo RL. Para cada valor de K , o AG produz dois arquivos: (i) a associação entre mercadorias e clusters; e (ii) os

conjuntos finais de berços por cluster, já compatíveis com a geração das tabelas de estados e ações.

Integração com o framework de RL. As soluções geradas alimentam diretamente a construção das estruturas de Aprendizado por Reforço, uma vez que cada cluster define um ambiente reduzido, com seu próprio espaço de estados e ações. Isso permite que o Q-learning opere de forma modular, respeitando a heterogeneidade operacional da APPA e mantendo a complexidade do problema em níveis computacionalmente manejáveis.

A avaliação quantitativa completa das execuções do AG, incluindo convergência, distribuição dos berços por cluster, sensibilidade aos parâmetros e comparação entre diferentes valores de K , será apresentada no Capítulo de Estudos de Caso. Esses resultados demonstram que o procedimento proposto gera clusters coerentes com a estrutura operacional do porto e viabiliza o treinamento eficiente das tabelas Q necessárias ao modelo desenvolvido.

Ao reunir berços com comportamentos semelhantes em grupos distintos, os chamados *clusters*, é possível reduzir significativamente a complexidade do problema de alocação. Em vez de tratar o sistema como um único bloco de decisão, o modelo passa a operar sobre unidades menores, o que não apenas diminui o espaço de busca do algoritmo de Aprendizado por Reforço, mas também melhora a qualidade das decisões ao considerar as particularidades de cada grupo. Essa modularização do problema é uma estratégia fundamental para garantir escalabilidade e eficiência computacional, especialmente em ambientes portuários com alta variabilidade e múltiplos tipos de operação simultânea.

3.2.5 TREINAMENTO POR CLUSTER

Uma vez definidos os *clusters* de berços com base em suas similaridades operacionais, o processo de Aprendizado por Reforço é conduzido de forma independente para cada grupo. Essa abordagem permite o aprendizado de regras específicas para contextos distintos de operação, respeitando as particularidades logísticas e operacionais de cada conjunto de berços. Para isso, é construída uma *Q-Table* separada para cada *cluster*, responsável por armazenar os valores esperados de retorno para cada par estado-ação observado durante o treinamento.

Para tornar o processo computacionalmente viável, o tempo de serviço nos berços foi discretizado em seis níveis, o que, combinado à divisão por *clusters*, reduz substancialmente o espaço de estados. Essa simplificação preserva a representatividade da dinâmica portuária, ao mesmo tempo, em que permite que o treinamento seja conduzido de forma eficiente e escalável.

Sendo assim, a cada época de treinamento os valores da *Q-Table* são atualizados, seguindo a Equação 3.5, que incorpora os princípios de aprendizado incremental e otimização de longo prazo:

$$Q(s^t, a^t) \leftarrow Q(s^t, a^t) + \alpha \left[R(a_k^t, s^t) + \gamma \max_{a'} Q(s^{t+1}, a') - Q(s^t, a^t) \right] \quad (3.5)$$

Nessa equação, α representa a taxa de aprendizado, controlando o peso das novas informações sobre o conhecimento acumulado; γ é o fator de desconto, que define a importância das recompensas futuras; $R(a_k^t, s^t)$ é a recompensa obtida ao aplicar a ação a_k^t no estado s^t ; e s^{t+1} é o estado resultante após a transição. Ao aplicar essa equação de forma iterativa e separada para cada *cluster*, o modelo consegue capturar nuances operacionais específicas, resultando em diretrizes de decisão mais adaptadas e eficazes para o ambiente portuário em estudo.

Dessa forma, o processo de *Q-learning* empregado nesta pesquisa pode ser organizado em um conjunto estruturado de etapas, refletindo o ciclo iterativo de interação entre o sistema de decisão e o ambiente simulado. Essas etapas sintetizam o funcionamento do método e estabelecem a base operacional utilizada no treinamento independente de cada *cluster* de berços. O procedimento segue a lógica apresentada a seguir:

1. **Definição da estrutura da Q-table:** estabelece-se o conjunto de estados discretizados e o conjunto de ações possíveis, conforme construídos a partir da clusterização, da discretização do tempo de serviço e das configurações operacionais de cada grupo de berços;
2. **Seleção de um par estado–ação:** em cada época de treinamento, o algoritmo seleciona um par (s^t, a^t) da Q-table. O processo de seleção inclui escolhas aleatórias, de modo a ampliar a diversidade de trajetórias observadas;
3. **Cálculo da recompensa imediata:** uma vez aplicada a ação a^t no estado s^t , o ambiente retorna a recompensa $R(a^t, s^t)$, correspondente ao impacto da decisão sobre o desempenho operacional;
4. **Atualização da Q-table:** utilizando a Equação 3.5, o valor de $Q(s^t, a^t)$ é ajustado a partir da diferença temporal entre a estimativa atual e a estimativa futura maximizada, incorporando assim o aprendizado incremental do modelo.
5. **Iteração ao longo das épocas:** os passos anteriores são repetidos para todas as épocas de treinamento. Ao longo das iterações, as estimativas da *Q-table* tendem a convergir para valores mais consistentes, refletindo um comportamento decisório progressivamente estável e adequado ao contexto operacional do respectivo *cluster*.

Essas etapas sintetizam o ciclo central do algoritmo, conectando o espaço de estados reduzido via clusterização à atualização sucessiva dos valores da *Q-Table*. Tal processo possibilita que o aprendizado ocorra de maneira distribuída e modular, resultando em estratégias de alocação mais robustas e ajustadas às condições específicas de cada agrupamento de berços.

3.2.6 Q-TABLE

A Q-table é o elemento central do processo de Aprendizado por Reforço, representando o valor esperado de retorno para cada par estado–ação durante o treinamento. Para cada *cluster*

de berços definido na etapa de pré-processamento, constrói-se uma Q-table independente, permitindo que o aprendizado reflita as particularidades operacionais daquele agrupamento.

A estrutura da Q-table possui duas dimensões: o conjunto de estados S , disposto nas linhas, e o conjunto de ações A , organizado nas colunas. Cada célula da matriz contém o valor $Q(s,a)$, que quantifica o benefício esperado de executar a ação a quando o sistema se encontra no estado s .

DIMENSÃO DO CONJUNTO DE ESTADOS

O conjunto de estados é formado pela combinação de condições de ocupação dos berços. Cada berço assume um entre seis níveis discretizados de tempo remanescente de serviço, representados por valores inteiros de 0 a 5. Assim, para um *cluster* composto por n berços:

$$|S| = 6^n.$$

Como exemplo, no *cluster* contendo sete berços, utilizado nos experimentos iniciais:

$$|S| = 6^7 = 279,936.$$

Exemplos ilustrativos de estados incluem:

- $[0,0,0,0,0,0,0]$: todos os berços estão livres;
- $[1,0,0,0,0,0,0]$: o primeiro berço encontra-se ocupado por 1–3h, os demais estão livres;
- $[5,5,5,5,5,5,5]$: todos os berços apresentam ocupação entre 13–15h.

Cada vetor representa um estado completo da infraestrutura naquele instante.

DIMENSÃO DO CONJUNTO DE AÇÕES

O conjunto de ações descreve todas as operações possíveis ao receber um navio. Para cada berço e para cada tipo de mercadoria presente no *cluster*, são consideradas duas alternativas: operação sem atraso e operação com atraso. Adicionalmente, inclui-se uma ação especial de não alocação, utilizada quando nenhuma das operações disponíveis é aplicável.

Assim, para um *cluster* com b berços e c mercadorias, o número total de ações é:

$$|A| = 1 + 2bc.$$

No caso do *cluster* com sete berços e duas mercadorias:

$$|A| = 1 + 2 \cdot 7 \cdot 2 = 29.$$

Cada ação é representada pela tripla:

(berço, mercadoria, atraso),

onde o atributo “atraso” assume valor 0 (sem atraso) ou 1 (com atraso).

Exemplo de vetor de ações para um cluster:

$$A = [((\text{Berço } 0, \text{ none}, 0), (114, \text{Farelos}, 0), (114, \text{Farelos}, 1), \\ (114, \text{Grãos}, 0), (114, \text{Grãos}, 1), \dots, (214, \text{Grãos}, 1))]$$

Cada uma dessas combinações constitui uma coluna distinta da Q-table.

TAMANHO FINAL DA Q-TABLE

Dessa forma, a dimensão total de cada Q-table construída para os *clusters* é dada por:

$$|S| \times |A|.$$

Esse formato assegura que, para cada estado possível do sistema, exista uma avaliação explícita de todas as decisões admissíveis. As Q-tables completas, juntamente com seus desempenhos e resultados de convergência, são apresentadas no Capítulo a seguir.

3.2.7 PROCESSO DE SIMULAÇÃO

A avaliação da abordagem proposta é conduzida por meio de um simulador desenvolvido especificamente para representar a dinâmica estocástica do sistema portuário da APPA. Esse ambiente foi construído com base em dados históricos reais, permitindo reproduzir com fidelidade as condições operacionais observadas, como padrões de chegada de navios, tempos de operação por tipo de carga e restrições físicas dos berços. A simulação incorpora incertezas típicas do contexto portuário, como variações nos tempos de serviço e flutuações na demanda, refletidas por meio de uma distribuição binomial aplicada à evolução dos tempos restantes de atendimento nos berços, conforme detalhado na Seção 3.1.

O sistema opera em ciclos discretos de uma hora, nos quais decisões de alocação são tomadas em tempo real com base nos valores atuais das *Q-Table* treinadas para cada *cluster*. A cada ciclo, o simulador identifica os navios presentes na fila de espera, determina o *cluster* correspondente ao tipo de carga de cada embarcação e seleciona, dentre as ações viáveis, aquela que apresenta o maior valor Q para o estado atual. Essa escolha representa a estratégia aprendida, que busca maximizar o retorno esperado com base na experiência acumulada durante o treinamento.

Caso não haja berço disponível ou a ação selecionada viole alguma restrição física ou operacional, como incompatibilidade de calado, comprimento ou tipo de carga, o navio permanece na fila, acumulando tempo de espera. Esse mecanismo permite avaliar o impacto

de decisões subótimas e testar a capacidade do algoritmo de lidar com situações de congestionamento e competição por recursos.

A simulação segue um ciclo iterativo composto por cinco etapas principais:

1. Observação do estado atual do sistema, incluindo a chegada de novos navios;
2. Seleção da ação com maior valor na *Q-Table* correspondente ao *cluster*;
3. Verificação da viabilidade da ação segundo as restrições operacionais, com respeito ao modelo proposto na Subseção 2.3.1;
4. Execução da alocação ou incremento no tempo de espera, conforme aplicável;
5. Ao final do horizonte de simulação, calcula-se o valor final da simulação, contabilizando tempos acumulados de serviço e espera a partir da função objetivo 2.1 definida na Subseção 2.3.1.

EXEMPLO ILUSTRATIVO DO PROCESSO DECISÓRIO NO SIMULADOR

Para tornar mais clara a dinâmica de decisão adotada durante a simulação, apresenta-se a seguir um exemplo numérico simplificado, representativo de um ciclo típico de operação do modelo.

Considere um *cluster* composto por sete berços e dois tipos de carga (grãos e farelos). Em um determinado ciclo horário t , o estado do sistema é dado por:

$$s^t = [0,1,3,0,0,2,0],$$

onde cada elemento do vetor representa o nível discretizado de tempo remanescente de atendimento de um berço específico. Nesse estado, três berços estão livres (nível 0), enquanto os demais encontram-se ocupados com diferentes tempos residuais de serviço.

Suponha que, nesse mesmo instante, um navio transportando grãos chega ao sistema e passa a integrar a fila de espera. A partir desse evento, o simulador consulta a *Q-Table* associada ao *cluster* correspondente e avalia as ações admissíveis para o estado s^t . Considere, por simplicidade, três ações possíveis:

- a_1 : alocar o navio imediatamente ao Berço 114, sem atraso;
- a_2 : alocar o navio ao Berço 214, com atraso operacional;
- a_3 : não realizar alocação neste ciclo, mantendo o navio em espera.

Os valores armazenados na *Q-Table* para esse estado são, hipoteticamente:

$$Q(s^t, a_1) = -6, \quad Q(s^t, a_2) = -4, \quad Q(s^t, a_3) = -2.$$

Como a regra de alocação aprendida seleciona a ação com maior valor Q , o simulador escolhe a ação a_3 , mantendo o navio na fila durante esse ciclo. Essa decisão indica que, com base na experiência acumulada durante o treinamento, o modelo aprendeu que a espera temporária, naquele estado específico, tende a resultar em menor penalização global do sistema do que uma alocação imediata, seja por evitar congestionamento futuro, seja por permitir melhor utilização dos berços em ciclos subsequentes.

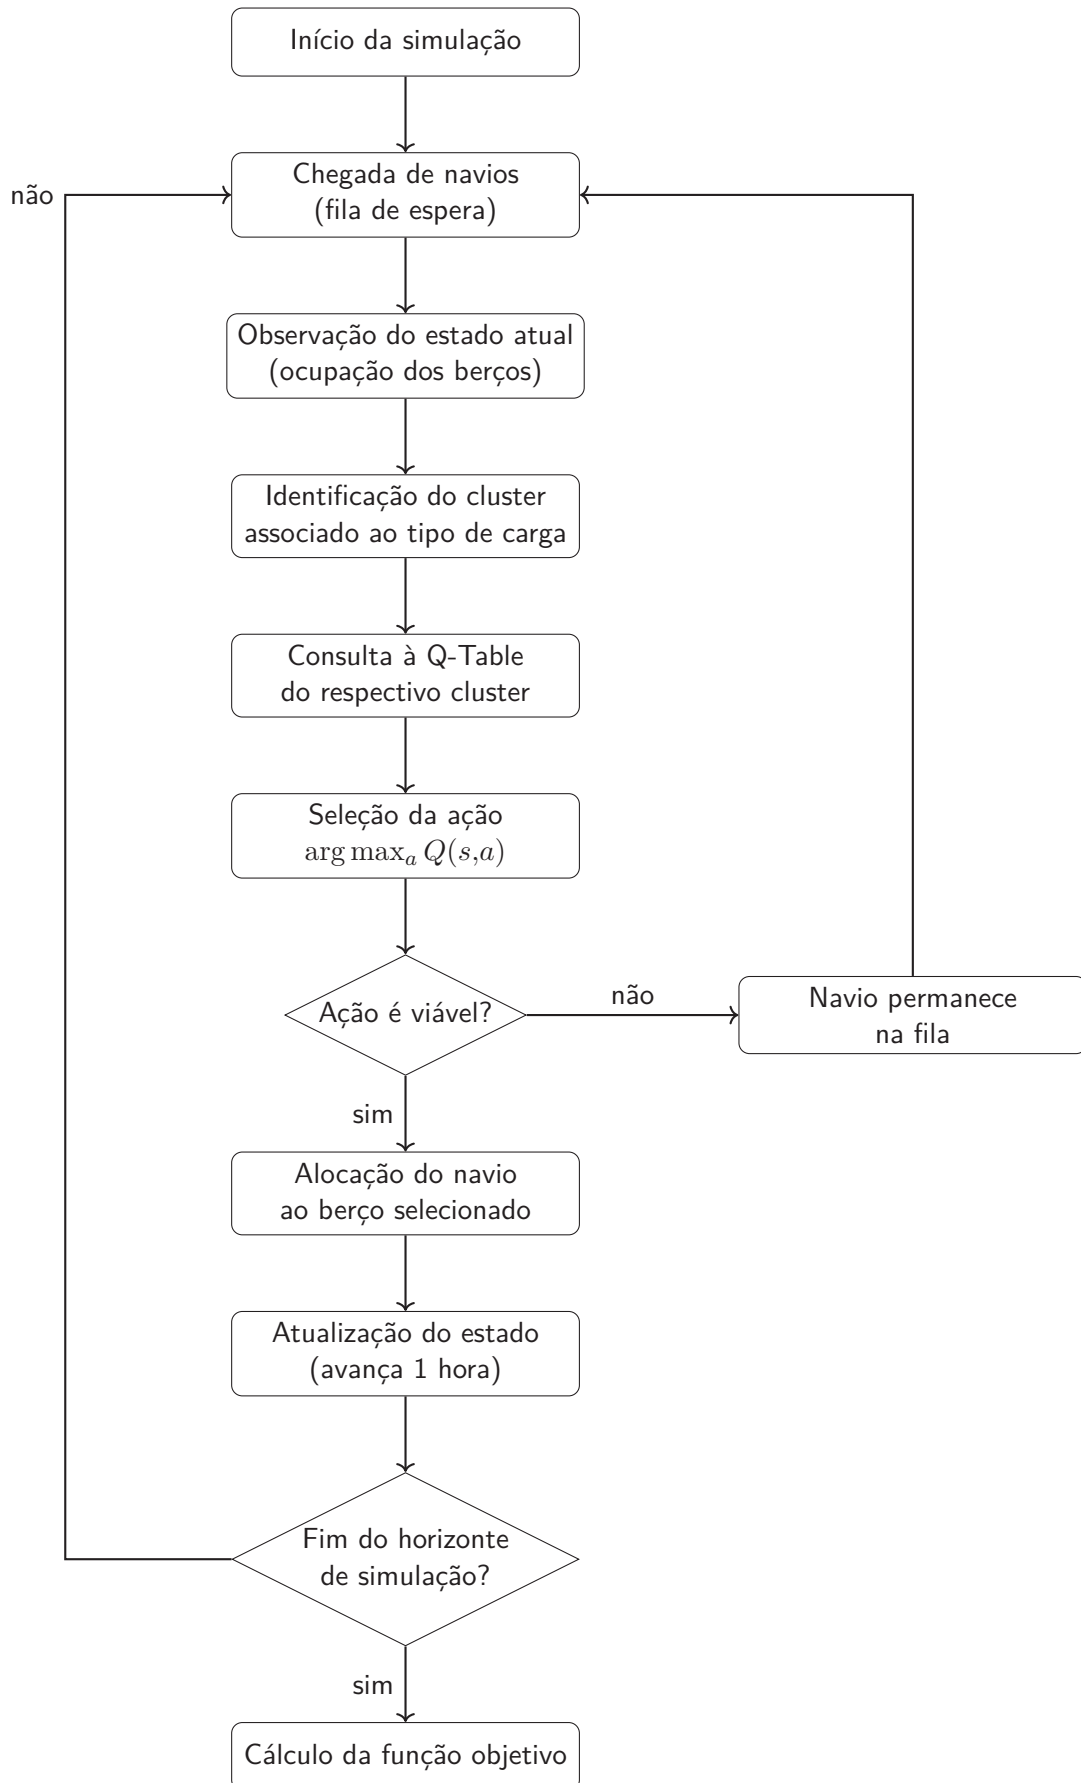
Após a execução da ação, o sistema evolui para um novo estado s^{t+1} , no qual os tempos remanescentes dos berços ocupados são atualizados e o tempo de espera do navio é incrementado. A recompensa associada à decisão, $R(a_3, s^t)$, é então calculada com base na função objetivo definida na Subseção 2.3.1, refletindo o impacto da espera adicional sobre o desempenho do sistema.

Esse valor é utilizado para atualizar a entrada correspondente da Q -Table, segundo a Equação 3.5, ajustando o valor de $Q(s^t, a_3)$. Ao longo de sucessivos ciclos e episódios de simulação, esse mecanismo permite que o algoritmo refine progressivamente suas estimativas, aprendendo quando é preferível alocar imediatamente um navio e quando a postergação da decisão conduz a um desempenho operacional superior.

A Figura 2 ilustra de forma esquemática a dinâmica do processo de simulação, explicitando o ciclo de observação do estado, seleção da ação via Q-learning, verificação de restrições operacionais e atualização do sistema ao longo do horizonte temporal.

Esse ambiente simulado permite testar o desempenho do algoritmo em diferentes cenários operacionais, variando o volume de tráfego, a composição da carga e a disponibilidade dos recursos. Nos estudos de casos apresentados a seguir, são exploradas configurações distintas para validar a robustez e a eficácia da abordagem baseada em Q -learning adaptado.

Figura 2 – Fluxograma do processo de simulação. A cada ciclo horário, o sistema observa o estado atual, consulta a Q-Table correspondente ao cluster do navio, seleciona a ação com maior valor esperado, verifica sua viabilidade operacional e atualiza o estado do sistema até o fim do horizonte de simulação.



4 ESTUDOS DE CASOS E EXPERIMENTOS COMPUTACIONAIS

Este capítulo apresenta os experimentos computacionais conduzidos para avaliar o desempenho da abordagem de Aprendizado por Reforço proposta para o Problema de Alocação de Berços (PAB). Os experimentos utilizam dados operacionais reais do porto de Paranaguá (APPA) e têm como foco a análise do impacto da modelagem por *clusters* de berços e do treinamento independente das *Q-Tables* na qualidade das decisões de alocação.

O desempenho do método proposto é comparado com políticas de referência amplamente utilizadas na prática portuária: *FIFO* (*First-In First-Out*) e *PHT* (*Priority of Handling Time*). As comparações são realizadas sob os mesmos cenários operacionais, permitindo avaliar ganhos relativos em termos de eficiência do atendimento e redução de tempos acumulados de espera e operação.

A seguir, descrevem-se os dados empregados, os procedimentos de pré-processamento e a configuração dos cenários de simulação utilizados nos experimentos.

4.1 DADOS E PRÉ-PROCESSAMENTO

O conjunto de dados utilizado foi construído a partir de múltiplas fontes confiáveis. Os relatórios da Portos do Paraná ((2025)) forneceram registros históricos de atracações, informações sobre os berços e detalhes operacionais dos navios, incluindo preferências de carga. Dados do MarineTraffic ((2025)) foram utilizados para caracterizar as embarcações, como comprimento, calado e tipo de carga, embora algumas lacunas tenham sido supridas com informações complementares obtidas junto à NOAA ((2025)), que também disponibiliza atributos técnicos de navios. O período de observação abrangeu nove meses, de 15 de abril de 2024 a 13 de janeiro de 2025, totalizando 521 registros de embarcações.

Os dados foram organizados em três *dataframes* principais:

- **DF_Navios:** informações operacionais e físicas dos navios (calado, comprimento, tempo médio de operação, tipo de carga).
- **DF_Bercos:** características dos berços do porto (comprimento útil, profundidade, especialização operacional).
- **DF_Preferencias:** matriz de compatibilidade entre navios e berços, baseada em restrições físicas, operacionais e normativas. Construído a partir do *Regulamento de Programações, Operações e Atracções* disponibilizado pela Administração dos Portos de Paranaguá APPA (2025). Esse regulamento estabelece critérios formais para a alocação de berços,

como tipos de operação preferenciais, limites de comprimento de embarcação e restrições adicionais (ex.: prioridade de carga ou calado máximo).

Tabela 2 – Exemplo de Restrições e Preferências de Berços

Berço	Tipo de Operação Preferencial	Condições Adicionais
141	Granéis Líquidos	Prioridade para derivados de petróleo e álcool
201	Granéis Sólidos (Exportação)	Mínimo de 52.500 t de um único produto
215	Full-contêineres	Operações via Terminal de Contêineres de Paranaguá (TCP)

Fonte: elaborado pelo próprio autor (2025), com base em Portos do Paraná (2024).

Essas informações foram incorporadas como restrições operacionais na abordagem de RL, garantindo que as alocações de berços geradas sejam compatíveis com a prática portuária vigente. Assim, a simulação não apenas replica a dinâmica operacional observada nos dados históricos, mas também assegura conformidade com as normas regulatórias aplicáveis.

Antes da aplicação do algoritmo de Aprendizado por Reforço, foi realizado um criterioso pré-processamento dos dados. Conduziu-se uma análise exploratória voltada à identificação de padrões e compatibilidades operacionais relevantes para o desafio de alocação de berços. Essa etapa permitiu compreender com maior precisão as preferências de atracação associadas aos diferentes tipos de carga movimentados no Porto de Paranaguá, além de incorporar as restrições operacionais estabelecidas pela administração portuária.

4.2 INSTÂNCIAS SIMULADAS

Foram considerados quatro horizontes de planejamento: 24, 48, 72 e 168 horas. Para cada horizonte, geraram-se sistematicamente cenários de carga, envolvendo entre 40 e 90 navios nos três primeiros casos e filas de 100, 125, 150, 175 e 200 navios no horizonte de 168 horas, mantendo-se a distribuição observada nos dados históricos.

Os tempos de chegada dos navios foram gerados a partir de uma distribuição Normal (Gaussiana), parametrizada por uma média μ e um desvio padrão σ , definidos de acordo com o horizonte de simulação considerado. Os valores amostrados foram discretizados para unidades inteiras de tempo e truncados ao intervalo $[1, H]$, onde H representa o horizonte de planejamento em horas, garantindo que todas as chegadas ocorressem dentro do período analisado. Essa modelagem permite concentrar as chegadas em torno de um período médio de maior intensidade operacional, ao mesmo tempo em que preserva variabilidade suficiente para representar cenários de congestionamento e ociosidade observados nos dados históricos.

A Tabela 3 apresenta um exemplo de instância composta por cinco navios, construída com base nos dados descritos. São destacados o nome do navio, comprimento e calado (em metros), tipo de carga, horário de chegada e tempo do serviço (em horas).

Tabela 3 – Instância 5 Navios

Nome	Compr.	Calado	Carga	Chegada	Serviço
NAVIO37	203.2	10.7	FERTILIZANTES	10	11
NAVIO356	199.9	7.0	COMBUSTÍVEIS	11	13
NAVIO82	199.99	8.2	VEÍCULOS	11	9
NAVIO298	179.97	6.6	GRÃOS	11	15
NAVIO439	199.9	7.3	AÇÚCAR	12	6

Fonte: elaborado pelo próprio autor (2025).

4.3 EXPERIMENTO I — PROCESSO DE DIVISÃO DE *CLUSTER*

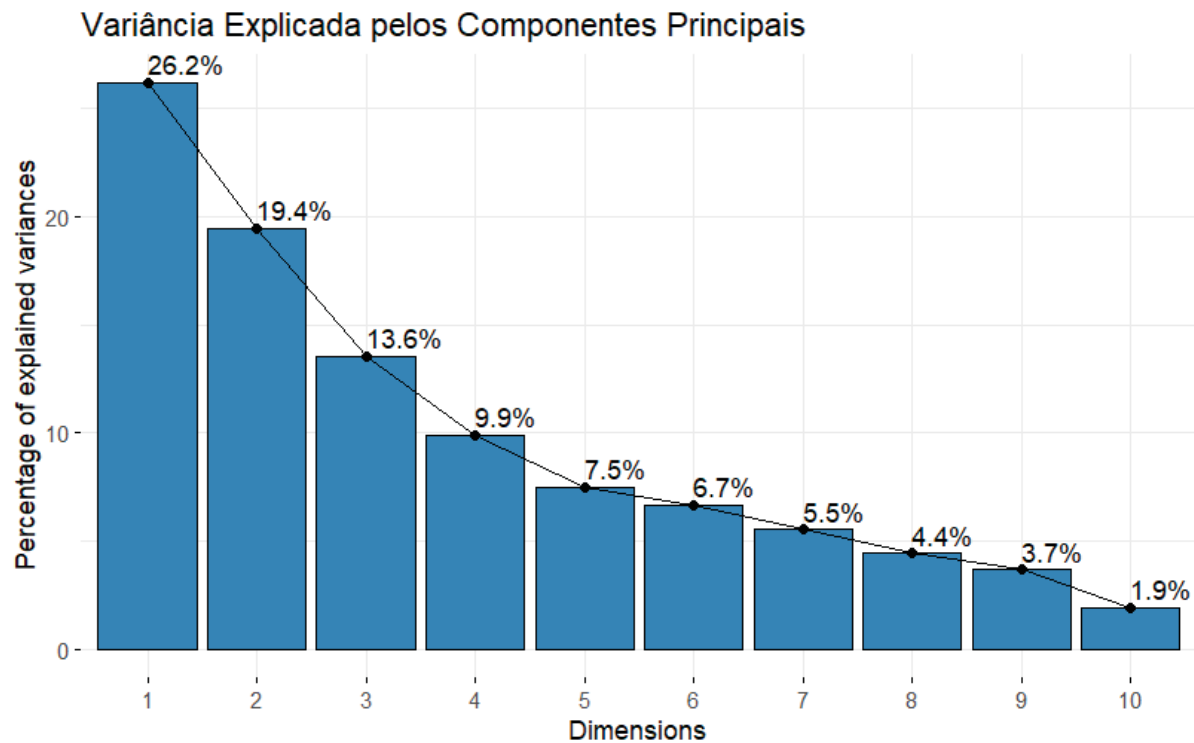
Este primeiro experimento teve como objetivo principal reduzir a dimensionalidade do espaço de estados por meio da formação de *clusters* de berços com características operacionais semelhantes. Ao agrupar berços de perfil análogo, busca-se representar o ambiente de forma mais compacta, sem comprometer a fidelidade operacional, viabilizando o treinamento das tabelas Q em escalas computacionalmente factíveis.

4.3.1 ANÁLISE DE COMPONENTES PRINCIPAIS (PCA) E AGRUPAMENTO COM K-MEANS

Buscando identificar grupos de berços com perfis operacionais semelhantes e reduzir a dimensionalidade do problema, aplicou-se a Análise de Componentes Principais (PCA) sobre dados históricos agregados por berço. Para cada berço, foram construídas variáveis representativas de sua operação, incluindo a frequência de atendimento por tipo de mercadoria, o volume movimentado e a diversidade de cargas atendidas ao longo do período analisado. Essas variáveis foram normalizadas de modo a eliminar efeitos de escala e permitir comparações diretas entre berços com diferentes níveis de utilização.

A análise dos *loadings* das componentes principais revelou padrões operacionais claros. A primeira componente principal (PC1) está fortemente associada à diferenciação entre granéis líquidos (combustíveis, produtos químicos e óleos) e granéis sólidos (fertilizantes, grãos e açúcar), enquanto a segunda componente (PC2) destaca berços com maior participação de cargas gerais, como contêineres, veículos e sal marinho. Assim, cada ponto projetado no plano PC1–PC2 representa um berço, cuja posição reflete seu perfil médio de atendimento de cargas (Figura 3).

Figura 3 – Variância explicada pelas componentes principais (PCA).




Fonte: elaborado pelo próprio autor (2025).

Com base nessa representação reduzida, aplicou-se o algoritmo k-means para identificar agrupamentos de berços com perfis operacionais semelhantes. A escolha do número de clusters foi realizada por meio do método do cotovelo, a partir da análise da soma dos quadrados intra-cluster (WCSS, Within-Cluster Sum of Squares), que corresponde à soma das distâncias quadráticas entre os pontos e seus respectivos centróides. Essa métrica permite avaliar o grau de compactação dos clusters, sendo utilizada para identificar o ponto em que o acréscimo de novos agrupamentos deixa de trazer ganhos significativos na redução da variabilidade interna. O gráfico apresentado na Figura 4 evidencia um ponto de inflexão para $k = 3$, indicando um compromisso adequado entre compactação dos grupos, interpretabilidade e complexidade computacional.

Embora o algoritmo k-means apresente limitações na segmentação de berços multipropósito, refletidas na sobreposição parcial entre grupos, os três clusters obtidos exibem coerência operacional clara e aderência à lógica observada nos dados históricos. Os agrupamentos podem ser descritos da seguinte forma:

- **Cluster 1 (Granéis Líquidos):** Berços especializados em combustíveis e produtos químicos.
- **Cluster 2 (Granéis Sólidos):** Berços de exportação de grãos, açúcar e fertilizantes.
- **Cluster 3 (Multipropósito):** Berços com perfil misto, incluindo contêineres e veículos.

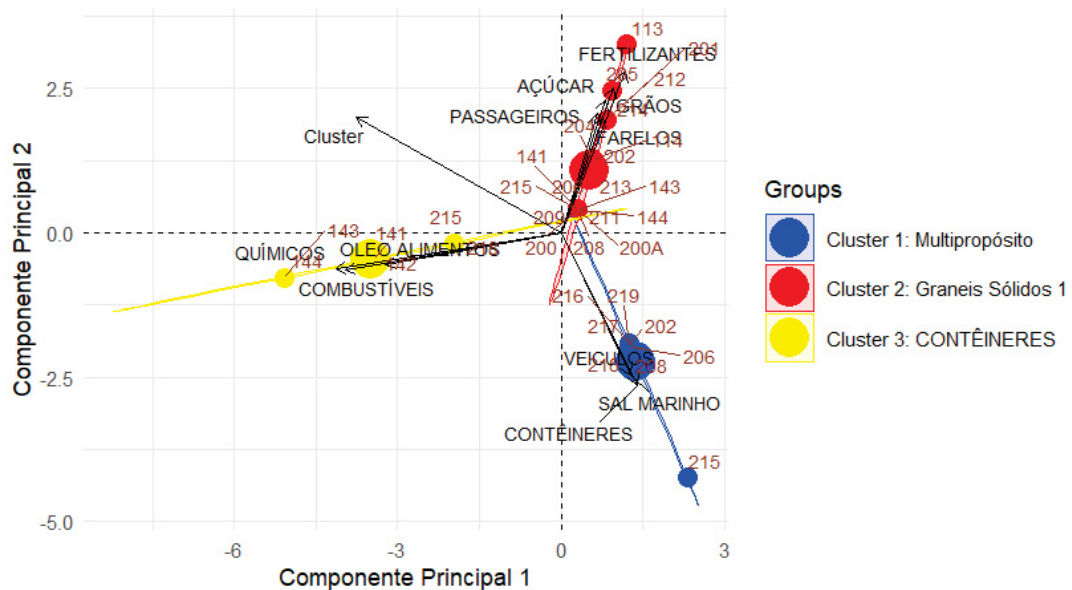
Figura 4 – Método do cotovelo aplicado ao k-means.



Fonte: elaborado pelo próprio autor (2025).

A Figura 5 apresenta os resultados da análise de PCA e clustering. Observa-se a formação de três clusters distintos, que representam as preferências de carga dos berços.

Figura 5 – Resultado da PCA e agrupamento dos berços.



Fonte: elaborado pelo próprio autor (2025).

Os clusters obtidos nessa etapa não são utilizados diretamente como decisões operacio-

nais, mas como uma representação intermediária da infraestrutura portuária. Essa segmentação é posteriormente explorada no modelo de Aprendizado por Reforço, no qual cada cluster de berços origina uma Q-table independente, permitindo reduzir significativamente o espaço de estados sem perder as principais distinções operacionais entre os berços.

4.3.2 CLUSTERIZAÇÃO FUNCIONAL COM ALGORITMO GENÉTICO (AG)

Abordagens preliminares baseadas na combinação de PCA e k -means mostraram-se úteis para revelar padrões iniciais de similaridade entre berços. Contudo, a elevada sobreposição observada entre berços multipropósito comprometeu a coerência funcional dos grupos formados, limitando sua aplicabilidade prática no contexto do PAB dinâmico. Em particular, a alocação de um mesmo berço a múltiplos clusters distintos ampliava artificialmente o espaço de estados e reduzia a especialização das regras de alocação aprendidas.

Diante disso, adotou-se um Algoritmo Genético (AG) como ferramenta de apoio à definição dos clusters funcionais, conforme descrito na Seção 3.2.4. O AG foi empregado não como um mecanismo de descoberta automática da lógica operacional do porto, mas como um método de busca capaz de explorar diferentes combinações de agrupamento, respeitando critérios operacionais previamente definidos. Essa abordagem permite sistematizar decisões que, embora fundamentadas em características físicas e operacionais conhecidas, envolvem múltiplos fatores de difícil avaliação simultânea.

A avaliação dos resultados da clusterização foi realizada para diferentes valores de $k \in \{5,6,7,8\}$, com base em três métricas complementares: diversidade, sobreposição e faixa de tamanho dos clusters. A Tabela 4 sintetiza os resultados obtidos.

A métrica de diversidade corresponde ao número médio de berços por cluster e fornece uma medida da capacidade de cada agrupamento em representar diferentes recursos. Valores mais elevados indicam maior cobertura funcional, enquanto valores reduzidos sugerem fragmentação excessiva. Já a faixa expressa o intervalo entre o menor e o maior número de berços por cluster, permitindo avaliar o balanceamento entre os grupos.

A métrica de sobreposição quantifica o grau em que um mesmo berço é alocado a mais de um cluster. Formalmente, ela é definida como:

$$\text{Sobreposição (\%)} = \frac{n_{\text{sobrep}}}{n_{\text{tot}}} \times 100 \quad (4.1)$$

onde n_{sobrep} é o número de berços atribuídos a mais de um cluster, e n_{tot} é o número total de berços distintos.

Essa medida é particularmente relevante neste estudo, pois a presença de sobreposição implica duplicação de estados no SDP e compromete diretamente a eficiência do treinamento por Aprendizado por Reforço.

Tabela 4 – Análise comparativa da clusterização por AG


k	Diversidade	Sobreposição	Faixa	Tendência
5	5,6	16,67%	4–7	–
6	4,83	20,83%	3–7	↑ Sobreposição
7	4,29	25,0%	1–7	↑ Sobreposição
8	4,0	33,33%	1–7	↑ Sobreposição

Fonte: elaborado pelo próprio autor (2025).

Os resultados evidenciam um balanceamento entre diversidade e sobreposição à medida que o número de clusters aumenta. Valores mais elevados de k tendem a fragmentar os berços em grupos menores, reduzindo a diversidade média e aumentando a probabilidade de sobreposição. Esse comportamento indica perda de coesão funcional e maior redundância estrutural no modelo.

Nesse contexto, o valor $k = 5$ apresentou o melhor compromisso entre cobertura funcional, balanceamento dos grupos e controle da sobreposição, configurando-se como a alternativa mais adequada para os experimentos subsequentes. A distribuição final dos berços para esse caso é ilustrada no mapa de calor da Figura 6, que evidencia a concentração funcional dos recursos e a redução de sobreposições indesejadas.

Figura 6 – Mapa de calor da distribuição de berços para $k = 5$ clusters, obtida por AG.



Fonte: elaborado pelo próprio autor (2025).

A escolha de $k = 5$ reflete, portanto, não apenas um critério numérico, mas um equilíbrio entre fidelidade operacional e viabilidade computacional. Valores menores de k

tendem a aglomerar excessivamente berços com vocações distintas, enquanto valores maiores fragmentam recursos cuja separação não é justificada do ponto de vista físico ou operacional.

Dessa forma, a clusterização obtida por meio do AG deve ser entendida como uma etapa preparatória, voltada à organização dos berços em agrupamentos funcionalmente coerentes. Ao respeitar restrições físicas e práticas operacionais, essa etapa fornece a base necessária para a modelagem do PAB como um SDP e para a especialização das políticas de alocação desenvolvidas no Experimento II.

É importante destacar que o processo de clusterização e organização dos berços, apoiado pelo uso de Algoritmos Genéticos, possui caráter eminentemente operacional. Trata-se de uma etapa fundamentada em características físicas e práticas consolidadas do sistema portuário, que orientam e delimitam as possibilidades de agrupamento. Nem todos os aspectos precisam ser formalizados em termos matemáticos: muitas decisões refletem restrições físicas e operacionais já estabelecidas, que funcionam como condições estruturais do problema.

4.4 ESCALABILIDADE COMPUTACIONAL DO ESPAÇO DE ESTADOS

Antes da apresentação do Experimento 2, torna-se necessário discutir a escalabilidade computacional associada ao espaço de estados do modelo de Aprendizado por Reforço empregado. O Problema de Alocação de Berços, quando representado de forma explícita, apresenta crescimento combinatorial do número de estados à medida que aumenta o número de berços considerados simultaneamente em cada decisão.

Mesmo após a discretização do tempo de serviço em seis níveis, o número total de estados cresce exponencialmente com o tamanho dos *clusters*. Por exemplo, um *cluster* com sete berços resulta em $6^7 = 279.936$ estados possíveis. Considerando um conjunto de 29 ações, a tabela Q associada ultrapassa 8 milhões de pares estado–ação.

Os resultados obtidos a partir das execuções computacionais, resumidos na Tabela 5, evidenciam o impacto direto desse crescimento sobre o tempo de treinamento. *Clusters* com até quatro berços apresentaram tempos de execução inferiores a um minuto, enquanto *clusters* com seis ou sete berços demandaram dezenas de milhões de épocas e tempos de processamento da ordem de dezenas de minutos.

Tabela 5 – Complexidade computacional das tabelas Q por tamanho do *cluster*

Berços	Estados	Ações	Épocas	Tempo (s)	Tempo (min)
2	36	13	10.000	0,05	≈ 0,00
3	216	17	5.000.000	45,3	0,76
4	1.296	21	5.000.000	52,1	0,87
5	7.776	25	5.000.000	59,4	0,99
6	46.656	27	23.000.000	312,6	5,21
7	279.936	29	162.400.000	2.310	38,5

Fonte: elaborado pelo próprio autor (2025).

Esses resultados foram obtidos em uma máquina equipada com processador Intel Core i5-13450HX (2,4 GHz), 10 núcleos e 24 GB de memória RAM. Observa-se que, mesmo em um ambiente computacional relativamente robusto, o treinamento direto do modelo sem estratégias de redução estrutural tornaria a análise inviável em cenários com múltiplas configurações de parâmetros.

Dessa forma, a clusterização dos berços não deve ser interpretada apenas como uma escolha metodológica, mas como um requisito prático para garantir a viabilidade computacional do modelo, preservando a representatividade operacional do sistema portuário analisado.

4.5 EXPERIMENTO II — VALIDAÇÃO DO ALGORITMO RL

O segundo Experimento teve como objetivo avaliar, de forma prática e detalhada, a eficácia da abordagem baseada em Aprendizado por Reforço (RL), aplicada ao Problema de Alocação de Berços (PAB) em cenários representativos do sistema APPA.

Para validar a abordagem, foram realizados três testes comparativos com as políticas tradicionais FIFO (*First-In, First-Out*) e PHT (*Priority of Handling Time*). Foram testadas estratégias de agrupamento entre 5 e 8 *clusters*, combinadas com diferentes configurações dos hiperparâmetros de aprendizado ($\alpha \in \{0,1; 0,5; 0,9\}$ e $\gamma \in \{0,1; 0,5; 0,9\}$), em simulações com horizontes de planejamento de 24, 48, 72 e 168 horas. Cada configuração foi repetida 30 vezes, de modo a reduzir os efeitos das variações estocásticas. A partir dessas repetições, foram calculadas as médias dos tempos acumulados de serviço e de espera.

Os cenários simulados foram construídos a partir de dados reais, respeitando a diversidade de cargas, os perfis dimensionais das embarcações e as restrições físicas dos berços. Os três testes abordaram, respectivamente: (i) a identificação da melhor combinação de hiperparâmetros para o horizonte de 24 horas, com foco na análise de desempenho frente a diferentes volumes de navios; (ii) o ranqueamento das dez melhores configurações entre todas as combinações de parâmetros e estratégias de clusterização, considerando os horizontes de 24, 48 e 72 horas; e (iii) a análise de desempenho da abordagem RL em cenários de alta demanda, com até 200 navios e horizonte estendido com 168 horas.

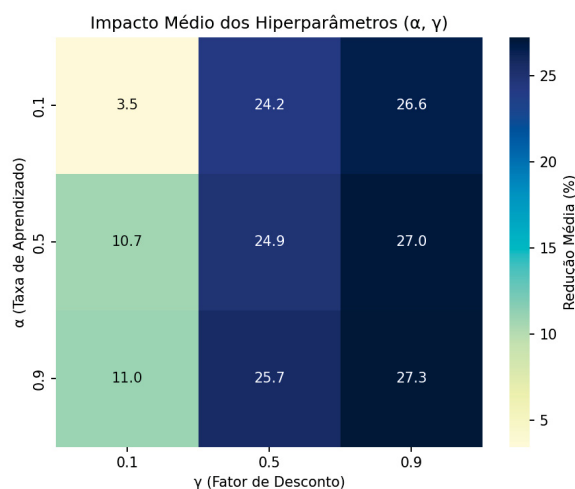
TESTE 1

O primeiro teste concentrou-se na avaliação da estratégia baseada em Aprendizado por Reforço frente às políticas operacionais tradicionais FIFO e PHT. Foram simulados cenários com diferentes volumes de navios (40 a 90 embarcações), com destaque para o caso de 90 navios, que representa uma situação de alta ocupação.

As análises concentram-se no horizonte de 24 horas, escolhido por representar um cenário operacional crítico, caracterizado por alta demanda e congestionamento na fila de navios. Esse recorte temporal reflete situações reais enfrentadas por operadores portuários, em que decisões precisam ser tomadas com agilidade para evitar atrasos e garantir o uso eficiente dos recursos disponíveis. Além de ser computacionalmente equilibrado para simulações, o cenário permite observar com clareza o comportamento de convergência do algoritmo e a influência dos hiperparâmetros no desempenho das estratégias de alocação extraídas das *Q-tables*.

A combinação $\alpha = 0,9$ e $\gamma = 0,9$, aplicada à clusterização em cinco grupos (Figura 7), apresentou o melhor desempenho, com redução no tempo total de estadia de até 27% em relação às abordagens tradicionais. Outras configurações também mostraram bons resultados, como $\alpha = 0,5$, $\gamma = 0,9$ e $\alpha = 0,9$, $\gamma = 0,5$, igualmente na estrutura de cinco clusters. A Figura 7 corresponde a um mapa de calor dos hiperparâmetros, gerado a partir da média das reduções observadas para cada combinação de α e γ . Esse gráfico evidencia o impacto médio dos hiperparâmetros na performance do RL, permitindo identificar regiões de ótimo local, como no caso de $\alpha = 0,9$ e $\gamma = 0,9$, e interpretar que valores elevados de α favorecem maior responsividade, enquanto valores altos de γ contribuem para a retenção de ganhos de longo prazo.

Figura 7 – Desempenho médio das combinações de α e γ na estrutura de 5 clusters.

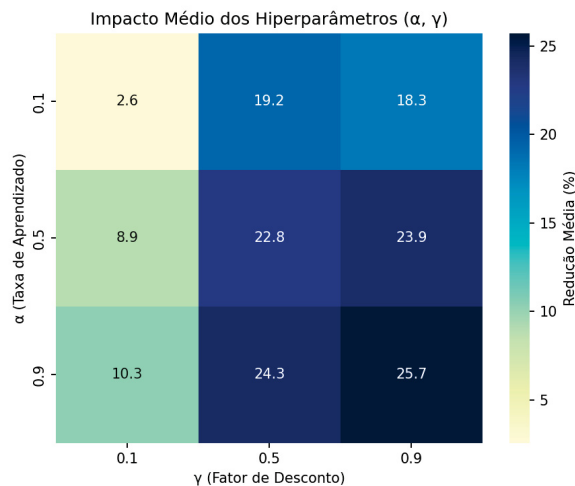


Fonte: elaborado pelo próprio autor (2025).

A Figura 8 ilustra as reduções médias no tempo total de permanência obtidas para

diferentes combinações dos parâmetros de aprendizado α e γ , considerando estruturas de cinco a oito clusters. O gráfico evidencia que, embora o cluster 5 permaneça como a configuração mais eficaz, os cenários com seis, sete e oito clusters apresentaram ganhos ligeiramente menores, indicando que o aumento da granularidade não se traduz necessariamente em maior eficiência operacional.


Figura 8 – Redução percentual do tempo total em função dos hiperparâmetros α e γ , para clusters 5–8.



Fonte: elaborado pelo próprio autor (2025).

A análise mostra que, nos testes com seis, sete e oito clusters, as reduções foram ligeiramente inferiores, alcançando até 25%, o que indica que o aumento no número de grupos não se traduziu em maior eficiência operacional. Já a clusterização com $k = 5$, obtida por meio do Algoritmo Genético (GA), apresentou o melhor desempenho médio, combinando diversidade estrutural e baixa sobreposição entre berços. A Figura 9 apresenta um mapa de calor construído a partir da média das reduções observadas, agrupadas por número de clusters e horizonte de simulação (24h, 48h e 72h). Esse gráfico permite visualizar como diferentes configurações impactam o desempenho em distintos horizontes de planejamento, evidenciando que a estrutura com cinco clusters tende a ser mais eficaz, especialmente em horizontes de 48 horas.

A Figura 10 apresenta os resultados agregados para diferentes configurações de clusterização dos berços. O gráfico foi construído a partir da média das reduções observadas, agrupadas pelo número de navios e pela quantidade de clusters, formando uma matriz que permite visualizar o impacto do congestionamento sobre o desempenho da abordagem. Observa-se que, com o aumento da fila de navios, as estratégias aprendidas pelo RL mantêm desempenho consistente mesmo em cenários de saturação, enquanto as políticas tradicionais tendem a perder eficiência. Os ganhos médios tornam-se mais expressivos em situações de alta ocupação, como no caso de 90 navios, reforçando a robustez e a superioridade da alocação baseada em RL frente às alternativas convencionais.

Figura 9 – Comparação desempenho RL $\alpha = 0.9 / \gamma = 0.9$ 

Fonte: elaborado pelo próprio autor (2025).

Figura 10 – Redução média por fila de navios e cluster





Figura 11 – Redução média por fila de navios e hiperparâmetros




Fonte: elaborado pelo próprio autor (2025).

Conforme mostra a Figura 11, o gráfico foi construído a partir da média das reduções observadas, agrupadas simultaneamente pelo número de navios e pelas combinações dos hiperparâmetros de aprendizado. Essa matriz evidencia o impacto conjunto da carga do sistema e das escolhas de α e γ sobre o desempenho da abordagem. A região de melhor desempenho concentra-se em $\alpha = 0.9, \gamma = 0.9$, indicando que o fator de desconto elevado foi determinante para estratégias mais estáveis sob carga intensa. Em termos operacionais, essa configuração representa um aprendizado capaz de antecipar atrasos futuros e priorizar alocações com maior retorno esperado ao longo do horizonte de 24 horas, além de demonstrar maior robustez em cenários de alta ocupação.

Os dados visuais da Figura 12 apresentam o tempo total acumulado em horas, considerando tanto os tempos de serviço realizados quanto as horas de atraso associadas a navios que permaneceram na fila aguardando atendimento.

Esses resultados reforçam a robustez da abordagem baseada em Aprendizado por Reforço, especialmente em cenários de alta ocupação e complexidade operacional. A capacidade

Figura 12 – Comparação desempenho RL $\alpha = 0.9 / \gamma = 0.9$ 

Fonte: elaborado pelo próprio autor (2025).

do algoritmo de adaptar-se dinamicamente às condições do sistema, aliada a sensibilidade aos hiperparâmetros e à precisão da clusterização, demonstra um potencial significativo para aplicações reais em ambientes portuários. A Tabela 6 apresenta os desempenhos observados para o cluster 5, destacando reduções expressivas no tempo total em diferentes horizontes de simulação.

Tabela 6 – Resultados observados para horizonte de 24 horas


Horas	Navios	Cluster	Custo Médio	Redução (%)	α / γ
24	90	cluster 5	965.00	33.41	0.9 / 0.9
24	80	cluster 5	865.10	30.72	0.9 / 0.9
24	70	cluster 5	754.50	30.37	0.9 / 0.9
24	60	cluster 5	643.80	27.38	0.9 / 0.9
24	50	cluster 5	535.60	23.00	0.9 / 0.9
24	40	cluster 5	424.33	18.66	0.9 / 0.9

Fonte: elaborado pelo próprio autor (2025).

ANÁLISE DETALHADA DOS DIAGRAMAS DE GANTT – FIFO E RL5


As Figuras 13 e 14 apresentam os diagramas de Gantt derivados diretamente da variável estrutural de ocupação dos berços. A análise a seguir reconstrói, hora a hora, as transições $0 \rightarrow 1$ (início de atendimento) e $1 \rightarrow 0$ (término de atendimento), permitindo examinar criticamente a dinâmica interna do sistema ao longo do horizonte de 24 horas.

Figura 13 – Diagrama de Gantt da ocupação dos berços (FIFO) – Horizonte 24 h



Fonte: elaborado pelo próprio autor (2025).

Figura 14 – Diagrama de Gantt da ocupação dos berços (RL – Cluster 5) – Horizonte 24 h



Fonte: elaborado pelo próprio autor (2025).

HORAS 1 A 3 – CONDIÇÃO INICIAL E PRIMEIRA EXPANSÃO

Na hora 1, a FIFO inicia dois atendimentos (ocupação = 2), enquanto o RL inicia apenas um atendimento (ocupação = 1). Embora a FIFO apresente ativação inicial mais intensa, essa diferença não se sustenta como vantagem estrutural. Nas horas 2 e 3, ambos mantêm ocupação estável, sem liberações, caracterizando fase de consolidação do regime inicial.

Do ponto de vista sistêmico, observa-se que o RL inicia de forma ligeiramente mais conservadora, preservando capacidade residual já nas primeiras horas.

HORA 4 – PRIMEIRA ACELERAÇÃO

Na hora 4, ambos iniciam três novos atendimentos. A FIFO atinge ocupação 5; o RL atinge 4. A diferença permanece marginal. Contudo, é relevante notar que nenhuma das políticas promove liberação até esse momento, configurando crescimento acumulativo típico da fase de carregamento do sistema.

HORAS 5 A 7 – FORMAÇÃO DE ALTA OCUPAÇÃO

Entre as horas 5 e 7, o crescimento se intensifica de forma progressiva. Na quinta hora, ambas as políticas registram acréscimo de um berço ocupado; na sexta, o aumento é de dois para cada uma. Já na sétima hora, a política FIFO cresce quatro unidades, enquanto o RL avança cinco. Nesse instante, ambas alcançam 12 berços ocupados, mas o RL realiza uma admissão adicional, evidenciando maior capacidade de absorção simultânea em cenário de crescimento acelerado.

Até esse ponto, nenhuma das políticas efetuou liberações, caracterizando ainda a fase de enchimento estrutural.

HORAS 8 A 10 – TRANSIÇÃO PARA REGIME CRÍTICO

Na hora 8 não há alterações.

Na hora 9, ambas iniciam quatro novos atendimentos, elevando a ocupação para 16. Na hora 10, ambas iniciam dois novos atendimentos, alcançando 18 berços ocupados.

Até a hora 10, o comportamento é simétrico: expansão intensa e ausência de escoamento. O sistema aproxima-se de zona crítica de saturação.

HORA 11 – PRIMEIRA LIBERAÇÃO

Na hora 11 ocorre a primeira liberação em ambas as políticas (-1), reduzindo a ocupação para 17. Trata-se de momento estrutural relevante: o sistema inicia processo de conversão de ocupação em atendimento concluído.

HORA 12 – DIVERGÊNCIA OPERACIONAL

Na hora 12 emerge a primeira diferença qualitativa significativa:

- FIFO: +1 entrada, nenhuma saída → ocupação = 18;
- RL: +3 entradas e -2 saídas → ocupação = 18.

Embora ambas terminem a hora com mesma ocupação (18), o RL realizou cinco movimentações operacionais (3 entradas e 2 saídas), enquanto a FIFO processou apenas um. O RL apresenta maior rotatividade interna, substituindo embarcações e mantendo fluxo ativo. Essa diferença é estrutural: a ocupação final é idêntica, mas evidencia maior capacidade estrutural de rotatividade.

HORAS 13 A 16 – PRESSÃO ELEVADA E FORMAÇÃO DE SATURAÇÃO

Na hora 13, a FIFO retoma sua expansão acumulativa, acrescentando dois berços e alcançando ocupação de 20, enquanto o RL permanece estável em 18. Já na hora 14, a FIFO registra uma entrada e uma saída, mantendo-se em 20, ao passo que o RL processa duas entradas e uma saída, chegando a 19 e demonstrando maior atividade líquida, com rotatividade superior. Na hora 15, ambas crescem de forma paralela: a FIFO adiciona um berço e atinge 21, enquanto o RL também acrescenta um, alcançando 20. Por fim, na hora 16, a FIFO continua acumulando, elevando sua ocupação para 22, enquanto o RL se mantém estável em 20. Nesse ponto, consolida-se a diferença estrutural: a FIFO segue acumulando até 22 berços, aproximando-se do limite físico, enquanto o RL estabiliza dois berços abaixo, evitando a pressão imediata sobre a capacidade máxima.

HORAS 17 A 19 – SATURAÇÃO PROLONGADA VERSUS ESTABILIZAÇÃO

Na hora 17, a FIFO mantém-se em 22 berços ocupados, sem novas movimentações, enquanto o RL acrescenta uma entrada e alcança 21. Na hora 18, ambos permanecem estáveis: a FIFO em 22 e o RL em 21. Já na hora 19, ocorre novo crescimento paralelo, com a FIFO atingindo 23 e o RL chegando a 22. Nesse momento, a FIFO entra em regime praticamente saturado, enquanto o RL continua crescendo, mas preserva um nível abaixo.

A diferença torna-se crítica: a FIFO permanece com ocupação maior ou igual a 22 berços durante seis horas consecutivas (entre as horas 18 e 23), evidenciando tendência de saturação prolongada. O RL, por sua vez, só alcança esse patamar por duas horas, demonstrando maior capacidade de estabilização e evitando pressão imediata sobre o limite físico. Em termos práticos, a FIFO privilegia o acúmulo máximo, mas corre risco de bloqueio operacional em cenários de alta demanda. O RL, ao manter margem de dois berços livres, sacrifica ocupação máxima em troca de flexibilidade e resiliência, o que pode ser decisivo em contextos de variabilidade intensa.

HORAS 20 A 23 – CAPACIDADE DE DESCOMPRESSÃO

Na hora 20 ocorre a principal inflexão: a FIFO mantém-se estática em 23 berços ocupados, consolidando o regime de saturação, enquanto o RL reduz sua ocupação de 22 para 20, promovendo uma descompressão ativa. Na hora 21, a diferença se acentua, pois a FIFO

permanece em 23, mas o RL realiza nova saída e desce para 19. Na hora 22, ambas estabilizam, com a FIFO ainda saturada em 23 e o RL mantendo 19. Já na hora 23, o RL promove nova redução, retirando duas embarcações e alcançando 17, enquanto a FIFO continua inalterada em 23.

Entre as horas 20 e 23, o RL acumula redução de cinco berços, evidenciando capacidade de recomposição de margem operacional. A FIFO, por sua vez, permanece no nível máximo, sem qualquer descompressão. Essa assimetria é relevante: enquanto a FIFO sustenta ocupação plena com risco de bloqueio prolongado, o RL adota postura adaptativa, mitigando a saturação e preservando capacidade de resposta diante de novas demandas. Em termos operacionais, a FIFO prioriza volume, ao passo que o RL privilegia estabilidade e sustentabilidade do fluxo.

HORA 24 – ESTADO FINAL

Na hora 24, a FIFO realiza uma saída e encerra o ciclo com ocupação final de 22 berços. O RL, por sua vez, combina uma entrada e uma saída, estabilizando em 17. Mesmo com nova admissão, o RL mantém ocupação significativamente inferior, reforçando sua estratégia de descompressão ativa.

SÍNTESE ANALÍTICA

Ao longo das 24 horas, observa-se um contraste estrutural entre as duas políticas. A FIFO processou 25 entradas e apenas 3 saídas, privilegiando o acúmulo contínuo e atingindo níveis próximos da saturação por longos períodos. Já o RL registrou 26 entradas e 10 saídas, evidenciando maior rotatividade interna e capacidade de liberar espaço.

Em termos práticos, a FIFO maximiza ocupação, mas corre o risco de bloqueio operacional em cenários de alta demanda, pois permanece longamente em patamares críticos. O RL, ao sacrificar parte da ocupação máxima, promove maior flexibilidade e resiliência, evitando saturação prolongada e preservando margem para absorver variações. Essa diferença revela duas lógicas distintas: a FIFO como política de volume bruto, e o RL como política de fluxo dinâmico e sustentável.

O RL realiza mais do que o triplo de liberações estruturais, mantém menor tempo em saturação elevada e encerra o horizonte com cinco berços a menos ocupados.

A análise hora a hora evidencia que a diferença não é episódica, mas cumulativa: o RL introduz rotatividade em pontos críticos (horas 12, 20 e 23), impedindo consolidação estrutural do congestionamento. A FIFO, ao priorizar apenas ordem cronológica, permite formação de estoque estrutural persistente.

Sob perspectiva de engenharia de sistemas portuários, o RL demonstra maior eficiência dinâmica, maior capacidade de processamento por unidade de tempo e melhor estabilidade sob carga elevada. A leitura minuciosa dos eventos confirma que a superioridade observada nos

indicadores agregados decorre de decisões localmente eficientes que, acumuladas ao longo do horizonte, produzem desempenho global superior.

TESTE 2

Complementarmente à análise apresentada no Teste 1, este segundo teste teve como objetivo identificar as configurações mais eficazes da abordagem baseada em RL, considerando diferentes horizontes de simulação e combinações de hiperparâmetros. No total, foram avaliados 648 cenários, resultantes da combinação dos parâmetros de aprendizado ($\alpha \in \{0.1, 0.5, 0.9\}$ e $\gamma \in \{0.1, 0.5, 0.9\}$), dos agrupamentos de berços (entre 5 e 8 *clusters*), dos tamanhos de fila (40, 50, 60, 70, 80 e 90 navios) e dos horizontes de planejamento (24, 48 e 72 horas). Todos os dados detalhados referentes a esses cenários encontram-se disponíveis no Apêndice 5.

A Tabela 7 apresenta os dez cenários de melhor desempenho, ranqueados com base na média do tempo acumulado, soma do tempo de serviço com o tempo de espera, e na redução percentual em relação à política FIFO, considerada a mais eficaz entre as estratégias heurísticas avaliadas. Esse ranqueamento revela padrões de configuração que favorecem a eficiência operacional, mesmo com diferentes horizontes de planejamento.

Tabela 7 – Melhores 10 resultados observados para diferentes horizontes de simulação

Horas	Navios	Cluster	Custo Médio	Redução (%)	α / γ
48	90	<i>cluster 5</i>	954.73	36.98	0.5 / 0.9
48	90	<i>cluster 5</i>	967.13	36.34	0.1 / 0.9
48	90	<i>cluster 5</i>	953.77	36.26	0.9 / 0.9
48	90	<i>cluster 5</i>	989.40	35.55	0.1 / 0.5
48	90	<i>cluster 6</i>	965.40	35.48	0.9 / 0.9
48	90	<i>cluster 6</i>	978.40	35.42	0.5 / 0.9
48	90	<i>cluster 5</i>	991.37	35.28	0.5 / 0.5
48	90	<i>cluster 5</i>	984.63	35.15	0.9 / 0.5
72	90	<i>cluster 5</i>	950.97	34.81	0.9 / 0.9
72	90	<i>cluster 5</i>	953.77	34.67	0.5 / 0.9


Fonte: elaborado pelo próprio autor (2025).

Os resultados mostram que todas as melhores configurações ocorreram em cenários com 90 navios, reforçando a capacidade da abordagem de RL em lidar com ambientes altamente congestionados. A proximidade entre os valores extremos de redução, variando de 34,67% a 36,98%, evidencia a robustez da abordagem frente a variações nos hiperparâmetros e nas estratégias de clusterização. O horizonte de 24 horas apresentou desempenho inferior em relação aos demais e, por esse motivo, não foi incluído entre os melhores resultados.

A Figura 15 apresenta o impacto médio das combinações de α e γ na redução percentual do tempo total, considerando os três horizontes de simulação. Como discutido na seção do 4.5, o gráfico sintetiza o efeito dos hiperparâmetros sobre o desempenho médio.

Observa-se que a configuração $\alpha = 0.9, \gamma = 0.9$ mantém desempenho elevado em todos os casos, reforçando sua eficácia e robustez frente às variações de horizonte.


Figura 15 – Redução percentual média por combinação de α e γ



Fonte: elaborado pelo próprio autor (2025).

Além disso, a Figura 16 evidencia o impacto da clusterização em diferentes horizontes de planejamento. A configuração com cinco clusters se confirma como a mais eficaz, alcançando ganhos médios de 20,1% em 24 horas, 20,2% em 48 horas e 15,4% em 72 horas. Apesar de o horizonte de 24 horas apresentar resultados consistentes dentro dessa estrutura, seu desempenho absoluto foi inferior aos cenários de maior duração, motivo pelo qual não figura entre os melhores resultados da Tabela 7.

Figura 16 – Desempenho médio por número de clusters e horizonte de simulação




Fonte: elaborado pelo próprio autor (2025).

Observa-se que o parâmetro de desconto $\gamma = 0,9$ esteve presente em sete dos dez melhores cenários, sugerindo que a valorização de recompensas futuras é um fator determinante para o desempenho da regra de alocação aprendida. Esse comportamento está alinhado

com a natureza sequencial do problema, em que decisões tomadas em instantes anteriores afetam diretamente a eficiência da alocação nos períodos subsequentes. Em relação à taxa de aprendizado α , os resultados comprovam maior diversidade: valores de 0,1, 0,5 e 0,9 aparecem entre os melhores casos, indicando que seu impacto depende mais da configuração específica do cenário, como o número de clusters e o horizonte de simulação. Em geral, valores mais altos de α aceleram a adaptação das estratégias de decisão em ambientes dinâmicos, enquanto valores intermediários tendem a estabilizar o aprendizado em cenários menos voláteis. A Figura 17 complementa essa análise ao mostrar que, mesmo com o aumento do número de navios, a abordagem baseada em RL mantém desempenho estável, com destaque para configurações que reduzem a sobreposição entre berços, reforçando a robustez do mecanismo de decisão aprendido em condições de alta ocupação.

Figura 17 – Redução média por volume de navios e número de clusters




Fonte: elaborado pelo próprio autor (2025).

A Figura 18 reforça que a combinação $\alpha = 0,9$, $\gamma = 0,9$ é especialmente eficaz em cenários congestionados, antecipando atrasos e otimizando a alocação ao longo dos diferentes horizontes. O gráfico evidencia que essa configuração mantém desempenho superior mesmo em situações de alta ocupação, confirmando sua robustez frente ao aumento da fila de navios. Cabe destacar que, embora tenham sido testadas configurações com horizontes de 72 horas e agrupamentos com 7 e 8 clusters, essas não figuraram entre os dez melhores resultados. Isso sugere que tais alternativas, ainda que promissoras em termos de detalhes, impõem maior complexidade computacional ou não oferecem ganhos significativos na representação do espaço de estados para este volume de navios.

ANÁLISE DOS DIAGRAMAS DE GANTT – FIFO E RL5 (HORIZONTE DE 48H)

A análise do horizonte de 48 horas, apresentada nas Figuras 19 e 20, permite avaliar não apenas o comportamento inicial das políticas, mas principalmente sua capacidade de sustentar desempenho sob regime prolongado e carga acumulada elevada. Diferentemente do horizonte de 24 horas, no qual os efeitos de congestionamento ainda estão em formação, o

Figura 18 – Redução média por volume de navios e hiperparâmetros

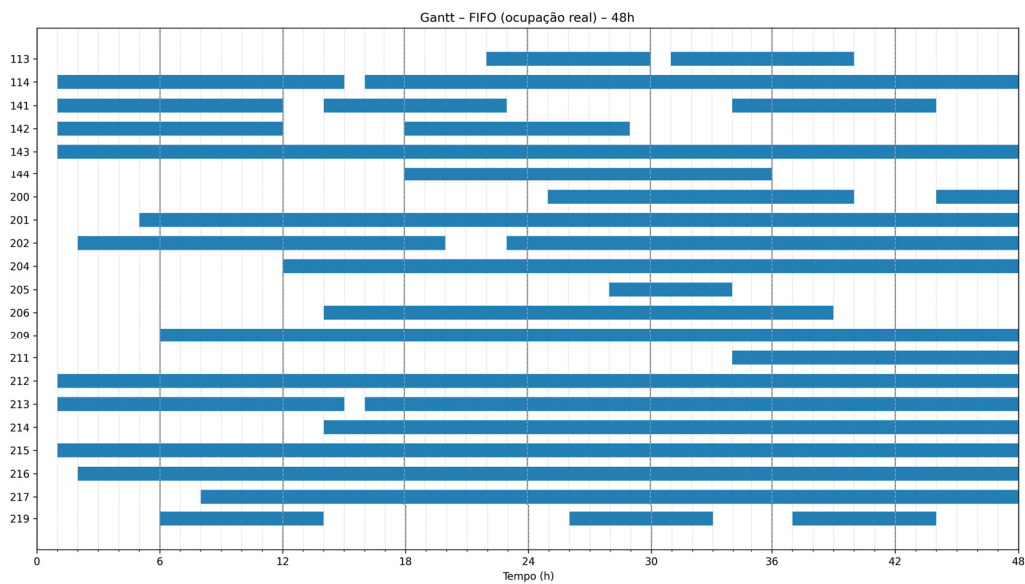


Fonte: elaborado pelo próprio autor (2025).

período de 48 horas evidencia a dinâmica completa de crescimento, estabilização e dissipação da ocupação dos berços.

A reconstrução foi realizada diretamente a partir das transições estruturais de ocupação, considerando, hora a hora, os eventos de início e término de atendimento. Assim, a análise reflete o estado físico efetivo do sistema em cada instante.

Figura 19 – Diagrama de Gantt da ocupação dos berços (FIFO) – Horizonte 48h




Fonte: elaborado pelo próprio autor (2025).

HORAS 1 A 10 – FORMAÇÃO DA BASE OPERACIONAL

No caso da FIFO, a operação inicia com sete atracções na hora 1 e duas na hora 2, atingindo nove berços ocupados já no segundo período. Entre as horas 3 e 4 não há movimentação, consolidando essa ocupação inicial. Novas entradas nas horas 5 e 6 elevam

Figura 20 – Diagrama de Gantt da ocupação dos berços (RL – Cluster 5) – Horizonte 48h



Fonte: elaborado pelo próprio autor (2025).

o nível para doze berços. Até a hora 11 não ocorre qualquer liberação. O sistema, portanto, opera durante onze horas consecutivas em regime estritamente acumulativo.

Na abordagem RL, observa-se padrão semelhante de formação da base inicial, com sete entradas na hora 2 e duas na hora 3, alcançando igualmente nove berços ocupados. Entretanto, a primeira liberação ocorre já na hora 9. Ainda que discreta, essa saída marca uma diferença estrutural importante: o sistema inicia a conversão da ocupação em atendimento concluído três horas antes da FIFO.

Até a hora 10, ambas atingem níveis próximos de ocupação (13 a 15 berços), mas o RL já demonstra alternância entre entradas e saídas, enquanto a FIFO permanece em regime de enchimento contínuo.

HORAS 11 A 18 – PRIMEIRA REGULUÇÃO SOB PRESSÃO

Entre as horas 11 e 18 consolida-se a primeira divergência significativa.

Na FIFO, a primeira redução líquida ocorre na hora 12, quando duas liberações superam a entrada registrada no período, reduzindo a ocupação de treze para doze berços. Nos períodos subsequentes, a dinâmica caracteriza-se por movimentos pontuais: aumento para quatorze na hora 14, redução para doze na hora 15, novo aumento para dezesseis na hora 18. As liberações são esparsas e reativas, sempre posteriores a períodos de acúmulo.

No RL, o comportamento é substancialmente distinto. Entre as horas 11 e 18 registram-se nove liberações distribuídas ao longo de sete horas. Destacam-se duas saídas na hora 11, duas na hora 12, duas na hora 17 e uma na hora 18. Ainda assim, a ocupação mantém-se em faixa relativamente estável, entre doze e dezesseis berços.

O que diferencia as políticas não é apenas o número de eventos, mas sua distribuição temporal. O RL promove substituições frequentes entre embarcações, mantendo elevada atividade interna sem permitir consolidação de estoque excessivo.

HORAS 19 A 27 – CRESCIMENTO E PICO OPERACIONAL

No intervalo seguinte observa-se novo aumento de entradas.

A FIFO eleva gradualmente sua ocupação, alcançando dezessete berços na hora 25, dezoito na hora 26 e dezenove na hora 28. As liberações permanecem limitadas e pontuais, não sendo suficientes para conter o crescimento estrutural do estoque.

O RL também cresce nesse intervalo, atingindo pico de vinte berços na hora 26, superando momentaneamente o máximo observado na FIFO. Contudo, diferentemente desta, inicia imediatamente processo de descompressão. Na hora 28 ocorrem três liberações simultâneas, reduzindo a ocupação de vinte para dezessete berços.

Essa diferença é decisiva: o RL admite crescimento quando necessário, mas evita prolongá-lo além do limiar operacional crítico.

HORAS 28 A 37 – DIVERGÊNCIA ESTRUTURAL

Entre as horas 28 e 36 emerge a maior diferença de comportamento.

Na FIFO, a ocupação oscila entre dezessete e dezoito berços, com liberações isoladas de uma unidade por vez. O sistema estabiliza-se em patamar elevado, sem tendência clara de redução.

No RL, por sua vez, ocorre sequência consistente de liberações: duas na hora 29, quatro na hora 33, duas na hora 37, além de eventos intermediários. Entre as horas 28 e 37 o sistema reduz sua ocupação de vinte para treze berços. Trata-se de descompressão ativa e coordenada.

Enquanto a FIFO permanece em regime quase estacionário de alta ocupação, o RL promove esvaziamento progressivo do sistema.

HORAS 37 A 48 – DISSIPACÃO FINAL

Na fase final do horizonte, a diferença torna-se ainda mais evidente.

A FIFO estabiliza-se entre quatorze e quinze berços ocupados e encerra o período com quatorze. A movimentação é mínima e o estoque residual permanece elevado.

O RL mantém sequência de liberações nas horas 39, 41, 44 e 46, reduzindo gradualmente a ocupação para sete berços na hora 48. O sistema aproxima-se de regime de equilíbrio com carga substancialmente menor que a observada na FIFO.

SÍNTESE ESTRUTURAL DO HORIZONTE DE 48 HORAS

Ao longo das 48 horas, o RL registra quarenta e seis entradas e trinta e nove liberações, enquanto a FIFO registra trinta e uma entradas e doze liberações. A diferença não é meramente quantitativa, ela revela diferenças estruturais no funcionamento do sistema.

A FIFO apresenta padrão acumulativo seguido de estabilização em patamar elevado, caracterizando formação de estoque estrutural persistente. O RL, ao contrário, alterna sistematicamente entre admissão e liberação, processando maior volume de embarcações sem permitir consolidação prolongada da ocupação.

A permanência em níveis elevados de ocupação por longos períodos, observada na FIFO, implica maior tempo médio implícito de permanência, maior exposição ao risco de atrasos em cascata e menor capacidade de absorver variações inesperadas. O RL, ao reduzir a ocupação de forma gradual na segunda metade do horizonte, demonstra controle intertemporal do sistema e maior estabilidade dinâmica.

Tabela 8 – Comparativo Estrutural FIFO × RL – Horizonte de 48 horas

Indicador	FIFO	RL	Superioridade RL (%)
Entradas em atendimento	31	46	+48,4%
Liberações (atendimentos concluídos)	12	39	+225,0%
Relação liberações/entradas	0,39	0,85	+117,9%
Saldo acumulado (entradas – liberações)	19	7	-63,2%
Ocupação final no horizonte	14	7	-50,0%

Fonte: elaborado pelo próprio autor (2025).

Os percentuais apresentados na coluna de superioridade do RL foram obtidos por comparação direta entre os valores observados sob cada política, tomando a FIFO como referência base. A regra geral de cálculo está formalizada na Equação 4.2, que expressa a variação relativa do desempenho do RL em relação à FIFO.

$$\text{Variação relativa (\%)} = \frac{\text{Valor RL} - \text{Valor FIFO}}{\text{Valor FIFO}} \times 100 \quad (4.2)$$

Para indicadores cujo aumento representa melhora operacional, como entradas em atendimento, liberações e razão liberações/entradas, valores positivos indicam desempenho superior da abordagem RL.

Para indicadores de natureza acumulativa ou de estoque, como saldo residual e ocupação final, valores negativos indicam redução estrutural sob RL, o que é interpretado como ganho sistêmico, pois implica menor formação de congestionamento.

No horizonte de 48 horas, o RL realiza 48,4% mais entradas em atendimento. O ganho é ainda mais expressivo no número de liberações: 39 contra 12, correspondendo a um aumento relativo de 225,0%. Esse resultado evidencia maior intensidade de processamento dentro do mesmo intervalo temporal.

A razão entre liberações e entradas, calculada como o quociente entre atendimentos concluídos e admissões no período, explicita a diferença estrutural de eficiência. A FIFO converte 39% das admissões em liberações dentro do horizonte analisado, enquanto o RL converte 85%. A variação relativa entre essas razões é de 117,9%, indicando praticamente o dobro de eficiência de conversão sob RL.

O saldo acumulado, definido como a diferença entre entradas e liberações ao final do horizonte, é reduzido em 63,2% sob RL (de 19 para 7 embarcações), evidenciando menor estoque operacional remanescente.

De forma consistente, a ocupação ao término do período é 50,0% inferior sob RL (14 contra 7), indicando maior capacidade de estabilização dinâmica e melhor condição inicial para o ciclo subsequente de planejamento.

Dessa forma, os percentuais apresentados não apenas quantificam diferenças absolutas, mas revelam distinções estruturais na forma como cada política administra fluxo, estoque e capacidade ao longo do horizonte ampliado de 48 horas.

IMPLICAÇÕES PARA O CONTEXTO DA APPA

No contexto da APPA, caracterizado por elevada variabilidade de chegadas, restrições físicas de berços e impacto direto do tempo de permanência sobre custos logísticos e competitividade regional, a capacidade de evitar consolidação de congestionamento é central.

O RL mostra-se superior não apenas por admitir embarcações, mas por converter ocupação em atendimentos concluídos com maior intensidade e regularidade. Isso reduz formação de filas externas, diminui risco de paralisações por saturação e preserva margem operacional para lidar com variações de maré, condições climáticas ou atrasos na cadeia logística terrestre.

Enquanto a FIFO mantém estabilidade apenas na regra de priorização, o RL mantém estabilidade operacional do sistema. Em horizonte prolongado, essa diferença torna-se estrutural: a primeira tende à manutenção de estoque elevado; a segunda converge para equilíbrio com menor carga acumulada.

Conclui-se que, no horizonte de 48 horas, a abordagem baseada em Aprendizado por Reforço apresenta desempenho superior não apenas em métricas agregadas, mas na própria organização dinâmica da utilização dos berços, aspecto fundamental para a gestão eficiente e sustentável das operações portuárias da APPA.

TESTE 3 — AVALIAÇÃO EM CENÁRIOS DE ALTA CARGA E HORIZONTE ESTENDIDO

Dando continuidade à avaliação dos ganhos obtidos pela abordagem baseada em RL, este terceiro teste teve como objetivo avaliar seu desempenho em cenários com maior densidade operacional e horizonte de planejamento estendido. A escolha por simular um intervalo de 168

horas, com volumes de 100, 125, 150, 175 e 200 navios, visa a representar condições mais próximas da realidade enfrentada por operadores portuários no sistema APPA, onde decisões precisam ser tomadas em contextos de alta complexidade e variabilidade logística.

Diferentemente dos testes anteriores, neste experimento não são apresentados diagramas de Gantt nem gráficos de evolução das filas. Essa decisão decorre do horizonte de simulação significativamente mais extenso (168 horas), o qual torna tais representações visuais excessivamente densas e de difícil interpretação, sem acréscimo substancial de informação analítica. Em horizontes longos, os diagramas passam a refletir predominantemente o efeito agregado das decisões ao longo do tempo, já capturado de forma mais objetiva pelas métricas consolidadas de desempenho apresentadas na Tabela 9 e nas Figuras 21 e 22.

Além disso, os Testes 1 e 2 já demonstraram de forma consistente que os ganhos observados em métricas agregadas estão diretamente associados a padrões operacionais mais estáveis, caracterizados por ocupação mais homogênea dos berços e mitigação da formação de filas persistentes. Assim, no contexto do Teste 3, a análise concentra-se deliberadamente na avaliação da estabilidade operacional em regime permanente e sob alta carga, privilegiando indicadores médios e comparativos que permitem avaliar a capacidade do sistema em sustentar desempenho superior ao longo do tempo, sem perda de generalidade ou rigor analítico.

A Tabela 9 apresenta os resultados médios obtidos para diferentes configurações de clusterização dos berços, com os hiperparâmetros fixados em $\alpha = 0,9$ e $\gamma = 0,9$, previamente identificados como os mais eficazes em cenários congestionados. Os valores indicam o tempo médio acumulado por cenário e a respectiva redução percentual em relação à política FIFO, utilizada como baseline.

Observa-se um impacto progressivo na redução obtida conforme o número de navios aumenta, considerando as diferentes configurações de clusterização apresentadas na Tabela 9. Com 100 embarcações, os ganhos iniciais foram modestos, refletindo a capacidade do algoritmo em filas menores. À medida que o fluxo cresce para 125 navios, a eficiência aumenta em cenários intermediários; com 150 e 175 navios, os ganhos tornam-se consistentes e adaptativos; e no caso extremo de 200 embarcações, a redução no cluster 5 alcançou 48,99%, consolidando o potencial do RL em congestionamentos severos. Embora o cluster 5 tenha apresentado os melhores resultados, os demais agrupamentos também demonstraram desempenho competitivo, mesmo diante da sobreposição estrutural identificada no Experimento I, o que sugere que a abordagem por RL consegue explorar com eficácia diferentes configurações espaciais e adaptar-se às restrições físicas e operacionais dos berços.

A análise por cluster, representada na Figura 21, evidencia diferenças sutis entre as configurações avaliadas. O cluster 5 apresentou a maior redução, com 33,3%, seguido pelo cluster 6, com 32,5%. Os clusters 7 e 8 registraram valores próximos, de 31,4% e 31,3%, respectivamente. Embora as diferenças sejam sutis, observa-se que configurações mais enxutas oferecem ganhos ligeiramente superiores, reforçando a necessidade de calibrar o número de clusters conforme o perfil operacional do porto.

Tabela 9 – Resultados para horizontes de simulação maiores (ordenados por número de navios)

Horas	Navios	Clusters	Custo Médio	Redução (%)
168	100	cluster 5	1043.53	16.89
168	100	cluster 6	1053.87	16.07
168	100	cluster 7	1069.23	14.84
168	100	cluster 8	1067.20	15.00
168	125	cluster 5	1310.93	26.64
168	125	cluster 6	1323.30	25.95
168	125	cluster 7	1348.17	24.56
168	125	cluster 8	1349.73	24.47
168	150	cluster 5	1572.67	31.64
168	150	cluster 6	1593.50	30.73
168	150	cluster 7	1618.40	29.65
168	150	cluster 8	1628.57	29.21
168	175	cluster 5	1842.47	42.43
168	175	cluster 6	1867.27	41.66
168	175	cluster 7	1897.70	40.71
168	175	cluster 8	1906.60	40.43
168	200	cluster 5	2110.50	48.99
168	200	cluster 6	2138.33	48.32
168	200	cluster 7	2182.40	47.25
168	200	cluster 8	2185.87	47.17

Fonte: elaborado pelo próprio autor (2025).

Figura 21 – Redução por cluster

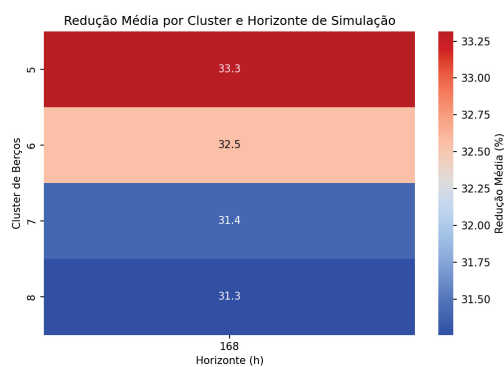
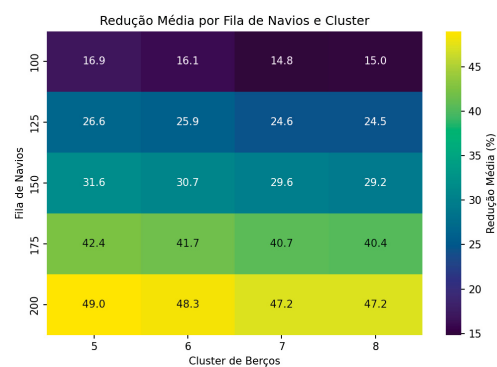


Figura 22 – Redução por fila de navios



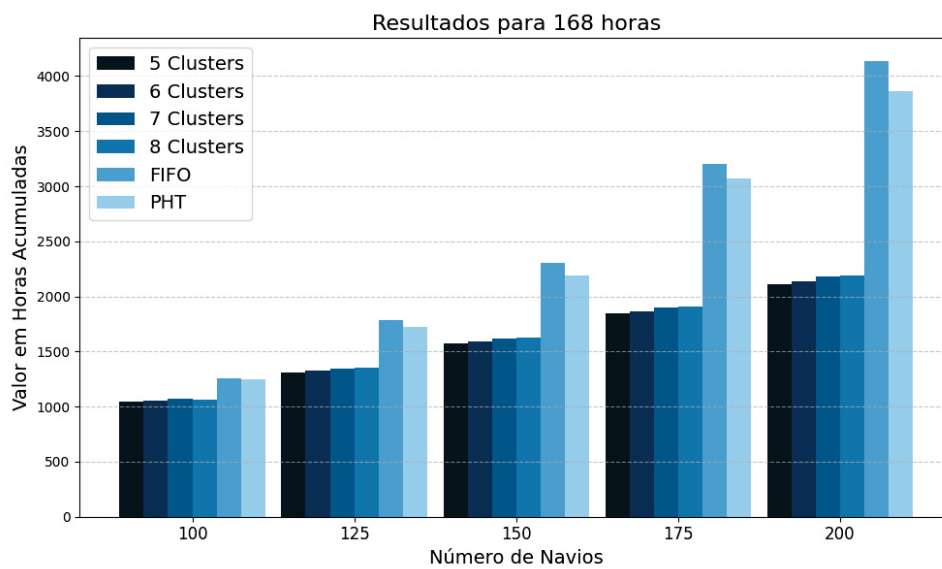
Fonte: elaborado pelo próprio autor (2025).

A Figura 22 detalha a interação entre o número de navios e os diferentes clusters, destacando a média de redução percentual. Em cenários de baixa demanda, como o de 100 embarcações, as reduções variaram entre 16,9% (cluster 5) e 14,8% (cluster 7), evidenciando diferenças mais perceptíveis entre configurações. Com 125 navios, os ganhos situaram-se entre 26,6% e 24,5%, enquanto para 150 navios alcançaram valores entre 31,6% e 29,2%. Em situações de maior pressão, como 175 embarcações, os resultados chegaram a 42,4% e 40,4%,

e no caso extremo de 200 navios oscilaram entre 49,0% e 47,2%. Consolidadamente, o cluster 5 apresentou desempenho ligeiramente superior, com média de 33,3%, frente a 32,5% do cluster 6, 31,4% do cluster 7 e 31,3% do cluster 8, confirmando sua robustez como configuração preferencial.

Os dados visuais da Figura 23 apresentam o tempo total acumulado em horas, considerando tanto os tempos de serviço realizados quanto as horas de atraso associadas a navios que permaneceram na fila aguardando atendimento.

Figura 23 – Comparação desempenho RL $\alpha = 0.$ / $\gamma = 0.9$



Fonte: elaborado pelo próprio autor (2025).

Um aspecto adicional é a consistência dos resultados mesmo diante da variabilidade estocástica das instâncias. Apesar do elevado número de execuções, os valores médios permaneceram estáveis, reforçando a robustez da abordagem e a adequação dos hiperparâmetros selecionados. A inexistência de necessidade de ajustes adicionais no processo de aprendizado indica que a abordagem pode generalizar bem, mesmo em cenários caracterizados por elevada heterogeneidade de cargas e perfis de embarcações.

De modo geral, os resultados do Teste 3 consolidam a eficácia da abordagem proposta para o Problema de Alocação de Berços (PAB), demonstrando sua capacidade de lidar com a complexidade do ambiente portuário e de oferecer soluções otimizadas em contextos operacionais realistas e desafiadores.

4.6 ANÁLISE CONSOLIDADA DOS RESULTADOS EXPERIMENTAIS

Os três testes realizados permitiram avaliar de forma abrangente a eficácia da abordagem baseada em Aprendizado por Reforço aplicada ao Problema de Alocação de Berços (PAB) no sistema APPA. A análise foi conduzida em diferentes escalas de complexidade, variando o número de navios, os horizontes de planejamento e as configurações de clusterização, sempre em comparação com as políticas operacionais tradicionais FIFO e PHT.

No Teste 1, verificou-se que a estratégias de decisão aprendida por RL supera de forma consistente as estratégias heurísticas em cenários de maior densidade de navios. A vantagem torna-se mais expressiva a partir de 70 embarcações, enquanto em cenários menos congestionados (como o de 40 navios) as políticas tradicionais ainda apresentam desempenho competitivo. A precisão da clusterização também se mostrou relevante, com destaque para o agrupamento em cinco clusters, que equilibra diversidade estrutural e viabilidade computacional.

O Teste 2 reforçou a robustez da abordagem ao ranquear os dez melhores cenários entre diferentes combinações de parâmetros e horizontes. A predominância de $\gamma = 0,9$ evidencia que a valorização de recompensas futuras é essencial para o desempenho.

Por fim, o Teste 3 demonstrou que os ganhos da abordagem RL são acumulativos em cenários de alta carga e planejamento estendido. Mesmo com 200 navios e horizonte de 168 horas, a estratégias de decisão aprendida manteve desempenho superior, alcançando reduções de até 48,99% em relação à FIFO. A consistência dos resultados, ainda que sob condições extremas, evidencia a capacidade de generalização da abordagem e sua aplicabilidade em contextos operacionais realistas e desafiadores.

De modo geral, os resultados consolidam o RL como uma alternativa viável e eficaz para a alocação dinâmica de berços, especialmente em ambientes portuários sujeitos a incertezas operacionais e variações logísticas. Além de superar de forma consistente as heurísticas tradicionais em cenários congestionados, as regras de decisão aprendidas demonstrou sensibilidade às configurações de parâmetros, reforçando a importância de uma calibragem cuidadosa para maximizar seu desempenho.

5 CONCLUSÕES

Este trabalho investigou o Problema de Alocação de Berços (PAB) no contexto real dos portos administrados pela Administração dos Portos de Paranaguá e Antonina (APPA), avaliando uma abordagem baseada em Aprendizado por Reforço (RL), com ênfase no algoritmo *Q-learning*. O PAB foi formulado matematicamente, como um problema discreto dinâmico, cuja evolução depende da ocupação e liberação dos berços ao longo do horizonte de simulação. Para resolver o *Q-learning*, modelou-se um processo de decisão sequencial, determinando o aprendizado capaz de escolher, a cada chegada de navio, um berço adequado considerando a dinâmica temporal e as restrições operacionais.

A complexidade do ambiente estudado, marcada pela heterogeneidade dos berços, diversidade de cargas e variabilidade da demanda, torna métodos fixos ou simplificados insuficientes. A análise do espaço de estados mostrou crescimento muito acelerado mesmo para cenários moderados, o que exigiu a aplicação de técnicas de redução dimensional. Assim, foram avaliadas duas estratégias de agrupamento de berços: PCA (Análise de Componentes Principais) e GA (Algoritmo Genético). O GA apresentou maior coerência operacional, preservando similaridades estruturais e funcionais relevantes para o processo de decisão. Essa redução foi fundamental para permitir que o algoritmo de RL convergisse e operasse de forma estável.

Com o estado reduzido, o Experimento II avaliou o desempenho do *Q-learning* em comparação a duas políticas de operação tradicionais amplamente empregadas em portos: FIFO (First-In, First-Out) e PHT (Priority of Handling Time). A primeira segue a ordem de chegada e a segunda prioriza navios com menor tempo de operação, ambas incapazes de capturar a interdependência temporal e espacial que caracteriza o PAB real.

Os resultados demonstraram que a estratégia de alocação aprendida pelo RL supera, em todos os cenários analisados, as abordagens FIFO e PHT. O melhor desempenho ocorreu no horizonte de 48 horas, com 90 navios e cinco clusters, alcançando custo médio de 954,73 e redução de 36,98% em relação às políticas comparadas. Outros cenários apresentaram reduções entre 34% e 36%, indicando robustez e consistência do método. Observou-se que a maior parte dos melhores resultados utilizou fator de desconto $\gamma = 0.9$, sugerindo que estratégias de decisão, que valorizam efeitos futuros tendem a produzir alocações mais eficientes. A predominância de arranjos com cinco clusters reforça a adequação dessa dimensionalidade reduzida para o aprendizado.

Outro ponto relevante é a adaptabilidade da estratégia aprendida. O *Q-learning* ajustou decisões de acordo com mudanças na disponibilidade dos berços, na distribuição temporal das chegadas e nas características dos navios. Essa capacidade é especialmente útil em portos multipropósito como os da APPA, onde a diversidade operacional e a variabilidade de demanda tornam decisões rígidas ineficientes. A abordagem de RL incorporou essas dependências sem

necessidade de regras específicas ou heurísticas manuais.

Do ponto de vista metodológico, o estudo mostrou que RL pode ser aplicado de forma eficaz ao PAB desde que o estado seja adequadamente reduzido. A combinação entre clusterização operacional e *Q-learning* foi determinante para garantir convergência e boa qualidade das decisões. Além disso, o uso de simulação permitiu comparar estratégias de forma controlada, segura e reproduzível, evitando riscos operacionais e permitindo explorar cenários extensos e congestionados.

Em síntese, este trabalho demonstra que a abordagem proposta é viável, eficiente e aplicável ao contexto real da APPA. A pesquisa estruturou o PAB como um problema discreto e dinâmico, formulado matematicamente de acordo com as características operacionais do porto, e o integrou a um processo de decisão sequencial que viabilizou o uso de Para tornar o método computacionalmente tratável, desenvolveu-se uma estratégia de redução do espaço de estados baseada em técnicas de agrupamento de berços, com destaque para o uso de Algoritmos Genéticos, cuja coerência operacional se mostrou decisiva para o desempenho da abordagem. Sob essa estrutura, os experimentos evidenciaram que a estratégia de alocação aprendida supera de forma consistente as abordagens tradicionais, apresentando ganhos expressivos mesmo em cenários de maior congestionamento e alinhando-se às restrições e particularidades reais da operação portuária.

Espera-se que esta pesquisa contribua tanto para a literatura quanto para aplicações futuras no âmbito da gestão portuária, especialmente em ambientes sujeitos a elevada variabilidade operacional. Além disso, abre-se espaço para avanços subsequentes que explorem métodos de aprendizagem profunda, integração com previsões probabilísticas, uso de dados operacionais em fluxo contínuo, otimização em tempo real e o desenvolvimento de abordagens híbridas que combinem RL com heurísticas e meta-heurísticas tradicionais, ampliando significativamente o potencial de aplicação do RL em sistemas portuários dinâmicos e multipropósito.

REFERÊNCIAS

- AGRA, Agostinho; RODRIGUES, Filipe. Distributionally robust optimization for the berth allocation problem under uncertainty. **Transportation Research Part B: Methodological**, Elsevier, v. 164, p. 1–24, 2022.
- APPA. **Administração dos Portos de Paranaguá e Antonina**. [S. l.: s. n.], jan. 2025. [Online; accessed 2025-01-10]. Disponível em: <https://www.portosdoparana.pr.gov.br/>.
- BACALHAU, Eduardo Tadeu; CASACIO, Luciana; AZEVEDO, Anibal Tavares de. New hybrid genetic algorithms to solve dynamic berth allocation problem. **Expert Systems With Applications**, Elsevier, v. 167, p. 114198, 2021. DOI: 10.1016/j.eswa.2020.114198.
- BARBOSA, Flávia. **O problema de alocação de berços: aspectos teóricos e computacionais**. 2014. Tese (Doutorado) – Universidade Estadual de Campinas, Campinas, SP. Instituto de Matemática, Estatística e Computação Científica.
- BARBOSA, Flávia *et al.* A brief survey of the berth allocation problem. **Pesquisa Operacional para o Desenvolvimento**, v. 8, p. 39–56, 1 2016.
- BELLMAN, Richard. **Dynamic Programming**. [S. l.]: Princeton University Press, 1957.
- BERTSEKAS, Dimitri P. **Dynamic Programming and Optimal Control**. 4. ed. [S. l.]: Athena Scientific, 2012. v. 1.
- BUHRKAL, K. *et al.* Models for the discrete berth allocation problem: A computational comparison. **Transportation Research Part E: Logistics and Transportation Review**, v. 47, p. 461–473, 2011.
- CERESER, B. L. H. *et al.* A Mathematical Model and Genetic Algorithm Solution Methods for the Berth Allocation Problem with Several Types of Machines. **Pesquisa Operacional**, v. 41, 2021.
- CERVELLERA, Cristiano *et al.* Policy Optimization for Berth Allocation Problems. **IEEE International Joint Conference on Neural Network**, 2021. DOI: 10.1109/ijcnn52387.2021.9533891.
- CORDEAU, Jean-François *et al.* Models and Tabu Search Heuristics for the Berth-Allocation Problem. **Transportation Science**, v. 39, p. 526–538, 4 2005. DOI: 10.1287/trsc.1050.0120.
- DAI, Y.; LI, Z.; WANG, B. Optimizing Berth Allocation in Maritime Transportation with Quay Crane Setup Times Using Reinforcement Learning. **Journal of Marine Science and Engineering**, v. 11, p. 1025, 2023.

DAI, Yonggai; LI, Zongchen; WANG, Boyu. Optimizing berth allocation in maritime transportation with quay crane setup times using reinforcement learning. **Journal of Marine Science and Engineering**, MDPI, v. 11, n. 5, p. 1025, 2023.

GUO, Liming; WANG, Jun; ZHENG, Jianfeng. Berth allocation problem with uncertain vessel handling times considering weather conditions. **Computers & Industrial Engineering**, Elsevier, v. 158, p. 107417, 2021.

HAMDAN, H. *et al.* Tackling the Berth Allocation Problem via Harmony Search Algorithm. **Iraqi Journal for Computer Science and Mathematics**, v. 5, n. 3, 2024.

HANSEN, P.; OGUZ, C. **A note on formulations of static and dynamic berth allocation problems**. [S. l.], 2003. p. 1–17.

HANSEN, P.; OGUZ, C.; MLADENOVIC, N. Variable neighborhood search for minimum cost berth allocation. **European Journal of Operational Research**, v. 191, p. 636–649, 3 2008. DOI: 10.1016/j.ejor.2006.12.057.

IMAI, A.; CHEN, H. C. *et al.* The simultaneous berth and quay crane allocation problem. **Transportation Research Part E: Logistics and Transportation Review**, v. 44, p. 900–920, 5 2008. DOI: 10.1016/j.tre.2007.03.003.

IMAI, A.; NAGAIWA, K.; TAT, C. W. Efficient planning of berth allocation for container terminals in Asia. **Journal of Advanced Transportation**, v. 31, p. 75–94, 1 1997.

IMAI, A.; NISHIMURA, E.; PAPADIMITRIOU, S. Berth allocation with service priority. **Transportation Research Part B: Methodological**, v. 37, p. 437–457, 5 2003. DOI: 10.1016/S0191-2615(02)00023-1.

IMAI, A.; NISHIMURA, E.; PAPADIMITRIOU, S. The dynamic berth allocation problem for a container port. **Transportation Research Part B: Methodological**, v. 35, p. 401–417, 4 2001.

IMAI, A.; SUN, X. *et al.* Berth allocation in a container port: using a continuous location space approach. **Transportation Research Part B: Methodological**, v. 39, p. 199–221, 2005.

KOLLEY, Lorenz *et al.* Robust berth scheduling using machine learning for vessel arrival time prediction. **Flexible Services and Manufacturing Journal**, 2022. DOI: 10.1007/s10696-022-09462-x.

LALLA-RUIZ, E.; MELIÁN-BATISTA, B.; MORENO-VEGA, J. M. Artificial intelligence hybrid heuristic based on tabu search for the dynamic berth allocation problem. **Engineering Applications of Artificial Intelligence**, v. 25, p. 1132–1141, 6 2012. DOI: 10.1016/j.engappai.2012.06.002.

- LIN, S. W.; YING, K. C.; WAN, S. Y. Minimizing the total service time of discrete dynamic berth allocation problem by an iterated greedy heuristic. **The Scientific World Journal**, p. 218925, 2014.
- LIU, Changchun; XIANG, Xi; ZHENG, Li. A two-stage robust optimization approach for the berth allocation problem under uncertainty. **Flexible Services and Manufacturing Journal**, v. 32, p. 425–452, 2020. DOI: 10.1007/s10696-019-09343-w.
- LV, Yaqiong *et al.* Dynamic berth allocation under uncertainties based on deep reinforcement learning towards resilient ports. **Ocean & Coastal Management**, Elsevier, v. 252, p. 107113, 2024.
- MARINETRAFFIC. **MarineTraffic: Global Ship Tracking Intelligence | AIS Marine Traffic**. [S. l.: s. n.], jan. 2025. [Online; accessed 2025-01-10]. Disponível em: <https://www.marinetraffic.com/en/ais/home/centerx:-12.0/centery:25.0/zoom:4>.
- MAURI, Geraldo Regis; DE OLIVEIRA, Alexandre César Muniz; LORENA, Luiz Antonio Nogueira. Heurística baseada no Simulated Annealing aplicada ao problema de alocação de berços. **Revista Gestão da Produção Operações e Sistemas**, n. 1, p. 113–113, 2008.
- MNASRI, S.; ALRASHIDI, M. A Comprehensive Modeling of the Discrete and Dynamic Problem of Berth Allocation in Maritime Terminals. **Electronics**, v. 10, p. 2684, 2021.
- MNASRI, S.; NASRI, N. A novel approach to resolve the Dynamic Discrete Berth Allocation Problem in a Container Terminal. **International Journal of Computational Intelligence in Science and Engineering**, v. 6, p. 615–625, 2014.
- MONACO, M. F.; SAMMARRA, M. The berth allocation problem: A strong formulation solved by a Lagrangean approach. **Transportation Science**, v. 41, p. 265–280, 2 2007. DOI: 10.1287/trsc.1060.0171.
- NOAA. **AIS Data for 2020**. [S. l.: s. n.], jan. 2025. [Online; accessed 2025-01-10]. Disponível em: <https://coast.noaa.gov/htdata/CMSP/AISDataHandler/2020/index.html>.
- OLIVEIRA, R. M. de; MAURI, G. R.; LORENA, L. A. N. Clustering Search for the Berth Allocation Problem. **Expert Systems with Applications**, v. 39, p. 5499–5505, 5 2012. DOI: 10.1016/j.eswa.2011.11.025.
- PRENCIPE, L. P.; MARINELLI, M. A novel mathematical formulation for solving the dynamic and discrete berth allocation problem by using the Bee Colony Optimisation algorithm. **Applied Intelligence**, 2020.

- RODRIGUES, Filipe; AGRA, Agostinho. Berth allocation and quay crane assignment/scheduling problem under uncertainty: A survey. **European Journal of Operational Research**, v. 303, p. 501–524, 2 2022. DOI: 10.1016/j.ejor.2021.12.040.
- SIMRIN, A.; DIABAT, A. The dynamic berth allocation problem: a linearized formulation. **RAIRO Operations Research**, v. 49, p. 473–494, 2015.
- SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement Learning: An Introduction**. Cambridge, MA: MIT Press, 1998. ISBN 978-0-262-19398-6.
- UNCTAD. **Launch of the Review of Maritime Transport 2024 | UNCTAD**. [S. l.: s. n.], 2024. <https://unctad.org/meeting/launch-review-maritime-transport-2024>. (Accessed on 10/23/2024).
- URSAVAS, Evrim; ZHU, Stuart X. Optimal policies for the berth allocation problem under stochastic nature. **European Journal of Operational Research**, v. 255, p. 380–387, 2 2016. DOI: 10.1016/j.ejor.2016.04.029.
- WANG, P.; LI, J.; CAO, X. Discrete Dynamic Berth Allocation Optimization in Container Terminal Based on Deep Q-Network. **Mathematics**, v. 12, p. 3742, 2024.
- WATKINS, Christopher J. C. H. **Learning from Delayed Rewards**. 1992. Tese (Doutorado) – University of Cambridge.
- YIN, D. *et al.* Static and Discrete Berth Allocation for Large-Scale Marine-Loading Problem by Using Iterative Variable Grouping Genetic Algorithm. **Journal of Marine Science and Engineering**, v. 10, n. 9, p. 1294, 2022.
- ZENG, Qingcheng; YANG, Zhongzhen; HU, Xiangpei. A method integrating simulation and reinforcement learning for operation scheduling in container terminals. **Transport**, Taylor & Francis, v. 26, n. 4, p. 383–393, 2011.
- ZHEN, L.; CHANG, D. F. A bi-objective model for robust berth allocation scheduling. **Computers & Industrial Engineering**, v. 63, p. 262–273, 1 2012. DOI: 10.1016/j.cie.2012.05.006.
- ZHEN, Lu; LEE, Loo Hay; CHEW, Ek Peng. A decision model for berth allocation under uncertainty. **European Journal of Operational Research**, v. 212, p. 54–68, 1 2011. DOI: 10.1016/j.ejor.2011.01.021.
- ZHOU, Qianyu; CAO, Xiaohua; WANG, Peng. Deep Reinforcement Learning for Dynamic Berth Allocation with Random Ship Arrivals. *In: IEEE. 2024 6th International Conference on Data-driven Optimization of Complex Systems (DOCS)*. [S. l.: s. n.], 2024. p. 799–805.

APÊNDICE A — RESULTADOS DETALHADOS DAS SIMULAÇÕES

Este apêndice apresenta os resultados completos das simulações realizadas, organizados por horizonte de planejamento (24h, 48h e 72h). Os valores incluem custo médio acumulado e redução percentual em relação à política FIFO, considerando diferentes configurações de clusterização e hiperparâmetros de aprendizado.

HORIZONTE DE 24H

Tabela 10 – Resultados médios para horizonte de 24h

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	40	5	507.03	1.70	0.1	0.1
24	50	5	668.77	4.47	0.1	0.1
24	60	5	843.67	3.55	0.1	0.1
24	70	5	1025.50	3.77	0.1	0.1
24	80	5	1203.13	3.36	0.1	0.1
24	90	5	1408.40	3.98	0.1	0.1
24	40	5	426.80	18.05	0.1	0.5
24	50	5	548.93	21.70	0.1	0.5
24	60	5	661.07	23.61	0.1	0.5
24	70	5	794.83	26.69	0.1	0.5
24	80	5	905.47	27.02	0.1	0.5
24	90	5	1041.90	28.27	0.1	0.5
24	40	5	424.57	19.01	0.1	0.9
24	50	5	528.17	23.99	0.1	0.9
24	60	5	641.47	27.04	0.1	0.9
24	70	5	762.13	28.13	0.1	0.9
24	80	5	879.90	29.64	0.1	0.9
24	90	5	989.80	31.65	0.1	0.9
24	40	5	492.13	5.25	0.5	0.1
24	50	5	641.20	7.93	0.5	0.1
24	60	5	779.93	11.18	0.5	0.1
24	70	5	951.23	11.48	0.5	0.1
24	80	5	1076.10	14.45	0.5	0.1
24	90	5	1251.17	14.11	0.5	0.1

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	40	5	440.27	16.50	0.5	0.5
24	50	5	549.83	19.79	0.5	0.5
24	60	5	661.80	24.98	0.5	0.5
24	70	5	777.53	26.91	0.5	0.5
24	80	5	896.20	29.23	0.5	0.5
24	90	5	1002.67	31.78	0.5	0.5
24	40	5	422.03	19.39	0.5	0.9
24	50	5	536.37	22.44	0.5	0.9
24	60	5	639.80	26.55	0.5	0.9
24	70	5	750.30	29.36	0.5	0.9
24	80	5	867.70	30.92	0.5	0.9
24	90	5	971.27	33.24	0.5	0.9
24	40	5	500.40	5.79	0.9	0.1
24	50	5	636.17	9.06	0.9	0.1
24	60	5	788.47	9.72	0.9	0.1
24	70	5	930.60	12.97	0.9	0.1
24	80	5	1086.30	14.02	0.9	0.1
24	90	5	1243.17	14.28	0.9	0.1
24	40	5	428.90	17.82	0.9	0.5
24	50	5	539.30	22.82	0.9	0.5
24	60	5	657.60	25.24	0.9	0.5
24	70	5	771.73	26.81	0.9	0.5
24	80	5	879.97	30.09	0.9	0.5
24	90	5	998.37	31.24	0.9	0.5
24	40	5	424.33	18.66	0.9	0.9
24	50	5	535.60	23.00	0.9	0.9
24	60	5	643.80	27.38	0.9	0.9
24	70	5	754.50	30.37	0.9	0.9
24	80	5	865.10	30.72	0.9	0.9
24	90	5	965.00	33.41	0.9	0.9
24	40	6	511.53	0.83	0.1	0.1
24	50	6	685.80	2.04	0.1	0.1
24	60	6	852.87	2.50	0.1	0.1
24	70	6	1040.27	2.39	0.1	0.1
24	80	6	1219.57	2.04	0.1	0.1
24	90	6	1433.80	2.25	0.1	0.1
24	40	6	456.70	12.31	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	50	6	588.60	16.04	0.1	0.5
24	60	6	718.70	16.95	0.1	0.5
24	70	6	871.47	19.63	0.1	0.5
24	80	6	989.20	20.27	0.1	0.5
24	90	6	1151.93	20.70	0.1	0.5
24	40	6	462.17	11.84	0.1	0.9
24	50	6	605.63	12.84	0.1	0.9
24	60	6	728.30	17.16	0.1	0.9
24	70	6	857.37	19.14	0.1	0.9
24	80	6	984.87	21.25	0.1	0.9
24	90	6	1136.53	21.51	0.1	0.9
24	40	6	494.07	4.88	0.5	0.1
24	50	6	640.70	8.00	0.5	0.1
24	60	6	809.13	7.85	0.5	0.1
24	70	6	971.70	9.57	0.5	0.1
24	80	6	1118.07	11.12	0.5	0.1
24	90	6	1289.13	11.51	0.5	0.1
24	40	6	443.40	15.91	0.5	0.5
24	50	6	554.83	19.07	0.5	0.5
24	60	6	678.07	23.13	0.5	0.5
24	70	6	806.77	24.17	0.5	0.5
24	80	6	933.90	26.25	0.5	0.5
24	90	6	1053.50	28.32	0.5	0.5
24	40	6	432.43	17.40	0.5	0.9
24	50	6	547.43	20.84	0.5	0.9
24	60	6	658.00	24.46	0.5	0.9
24	70	6	770.00	27.51	0.5	0.9
24	80	6	900.87	28.28	0.5	0.9
24	90	6	998.60	31.36	0.5	0.9
24	40	6	496.50	6.52	0.9	0.1
24	50	6	639.23	8.62	0.9	0.1
24	60	6	780.60	10.62	0.9	0.1
24	70	6	925.03	13.49	0.9	0.1
24	80	6	1081.80	14.37	0.9	0.1
24	90	6	1248.23	13.93	0.9	0.1
24	40	6	436.57	16.35	0.9	0.5
24	50	6	551.90	21.02	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	60	6	672.83	23.50	0.9	0.5
24	70	6	784.10	25.64	0.9	0.5
24	80	6	921.13	26.82	0.9	0.5
24	90	6	1041.53	28.27	0.9	0.5
24	40	6	429.70	17.63	0.9	0.9
24	50	6	539.70	22.41	0.9	0.9
24	60	6	652.67	26.38	0.9	0.9
24	70	6	766.40	29.27	0.9	0.9
24	80	6	875.47	29.89	0.9	0.9
24	90	6	989.53	31.71	0.9	0.9
24	40	7	508.27	1.46	0.1	0.1
24	50	7	683.10	2.42	0.1	0.1
24	60	7	857.67	1.95	0.1	0.1
24	70	7	1033.90	2.99	0.1	0.1
24	80	7	1217.37	2.22	0.1	0.1
24	90	7	1438.97	1.90	0.1	0.1
24	40	7	448.17	13.95	0.1	0.5
24	50	7	587.60	16.19	0.1	0.5
24	60	7	716.13	17.25	0.1	0.5
24	70	7	866.23	20.11	0.1	0.5
24	80	7	978.97	21.09	0.1	0.5
24	90	7	1136.40	21.77	0.1	0.5
24	40	7	474.40	9.51	0.1	0.9
24	50	7	610.37	12.16	0.1	0.9
24	60	7	741.37	15.68	0.1	0.9
24	70	7	863.57	18.56	0.1	0.9
24	80	7	1004.80	19.66	0.1	0.9
24	90	7	1151.63	20.47	0.1	0.9
24	40	7	495.20	4.66	0.5	0.1
24	50	7	652.10	6.37	0.5	0.1
24	60	7	806.13	8.19	0.5	0.1
24	70	7	998.33	7.09	0.5	0.1
24	80	7	1131.37	10.06	0.5	0.1
24	90	7	1308.27	10.19	0.5	0.1
24	40	7	450.53	14.56	0.5	0.5
24	50	7	559.90	18.33	0.5	0.5
24	60	7	687.83	22.03	0.5	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	70	7	815.07	23.39	0.5	0.5
24	80	7	935.77	26.10	0.5	0.5
24	90	7	1059.83	27.89	0.5	0.5
24	40	7	444.47	15.10	0.5	0.9
24	50	7	565.43	18.23	0.5	0.9
24	60	7	674.43	22.58	0.5	0.9
24	70	7	787.67	25.84	0.5	0.9
24	80	7	919.10	26.83	0.5	0.9
24	90	7	1023.60	29.64	0.5	0.9
24	40	7	499.10	6.03	0.9	0.1
24	50	7	647.43	7.45	0.9	0.1
24	60	7	791.07	9.42	0.9	0.1
24	70	7	945.27	11.59	0.9	0.1
24	80	7	1093.43	13.45	0.9	0.1
24	90	7	1284.07	11.46	0.9	0.1
24	40	7	443.80	14.96	0.9	0.5
24	50	7	550.83	21.17	0.9	0.5
24	60	7	674.37	23.33	0.9	0.5
24	70	7	785.63	25.49	0.9	0.5
24	80	7	899.77	28.52	0.9	0.5
24	90	7	1018.17	29.88	0.9	0.5
24	40	7	434.63	16.68	0.9	0.9
24	50	7	547.87	21.24	0.9	0.9
24	60	7	668.03	24.65	0.9	0.9
24	70	7	784.23	27.63	0.9	0.9
24	80	7	895.20	28.31	0.9	0.9
24	90	7	1011.13	30.22	0.9	0.9
24	40	8	505.23	2.05	0.1	0.1
24	50	8	679.47	2.94	0.1	0.1
24	60	8	847.37	3.12	0.1	0.1
24	70	8	1031.23	3.24	0.1	0.1
24	80	8	1219.00	2.09	0.1	0.1
24	90	8	1428.93	2.58	0.1	0.1
24	40	8	458.80	11.91	0.1	0.5
24	50	8	596.00	14.99	0.1	0.5
24	60	8	733.67	15.22	0.1	0.5
24	70	8	886.57	18.23	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	80	8	990.90	20.13	0.1	0.5
24	90	8	1173.33	19.23	0.1	0.5
24	40	8	483.23	7.82	0.1	0.9
24	50	8	625.30	10.01	0.1	0.9
24	60	8	760.17	13.54	0.1	0.9
24	70	8	897.47	15.36	0.1	0.9
24	80	8	1038.97	16.92	0.1	0.9
24	90	8	1195.57	17.43	0.1	0.9
24	40	8	492.87	5.11	0.5	0.1
24	50	8	647.30	7.05	0.5	0.1
24	60	8	797.93	9.13	0.5	0.1
24	70	8	987.13	8.14	0.5	0.1
24	80	8	1137.40	9.58	0.5	0.1
24	90	8	1312.77	9.88	0.5	0.1
24	40	8	455.37	13.64	0.5	0.5
24	50	8	565.63	17.49	0.5	0.5
24	60	8	692.50	21.50	0.5	0.5
24	70	8	821.43	22.79	0.5	0.5
24	80	8	948.27	25.11	0.5	0.5
24	90	8	1065.23	27.52	0.5	0.5
24	40	8	455.83	12.93	0.5	0.9
24	50	8	576.67	16.61	0.5	0.9
24	60	8	695.07	20.21	0.5	0.9
24	70	8	817.80	23.01	0.5	0.9
24	80	8	948.80	24.46	0.5	0.9
24	90	8	1057.90	27.28	0.5	0.9
24	40	8	503.63	5.18	0.9	0.1
24	50	8	650.27	7.04	0.9	0.1
24	60	8	802.07	8.16	0.9	0.1
24	70	8	956.67	10.53	0.9	0.1
24	80	8	1109.60	12.17	0.9	0.1
24	90	8	1286.37	11.30	0.9	0.1
24	40	8	440.23	15.65	0.9	0.5
24	50	8	553.73	20.76	0.9	0.5
24	60	8	669.57	23.88	0.9	0.5
24	70	8	780.80	25.95	0.9	0.5
24	80	8	912.37	27.52	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
24	90	8	1026.43	29.31	0.9	0.5
24	40	8	439.07	15.83	0.9	0.9
24	50	8	550.90	20.80	0.9	0.9
24	60	8	668.00	24.65	0.9	0.9
24	70	8	784.17	27.63	0.9	0.9
24	80	8	896.80	28.18	0.9	0.9
24	90	8	1002.57	30.81	0.9	0.9

HORIZONTE DE 48H

Tabela 11 – Resultados médios para horizonte de 48h

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	40	5	474.97	4.03	0.1	0.1
48	50	5	623.53	5.16	0.1	0.1
48	60	5	797.33	5.69	0.1	0.1
48	70	5	991.00	6.97	0.1	0.1
48	80	5	1206.10	6.70	0.1	0.1
48	90	5	1424.83	6.17	0.1	0.1
48	40	5	414.30	12.46	0.1	0.5
48	50	5	530.40	19.75	0.1	0.5
48	60	5	633.80	23.20	0.1	0.5
48	70	5	746.27	29.29	0.1	0.5
48	80	5	868.53	32.73	0.1	0.5
48	90	5	989.40	35.55	0.1	0.5
48	40	5	425.10	15.20	0.1	0.9
48	50	5	518.73	18.62	0.1	0.9
48	60	5	627.17	25.15	0.1	0.9
48	70	5	755.50	31.06	0.1	0.9
48	80	5	860.60	33.69	0.1	0.9
48	90	5	967.13	36.34	0.1	0.9
48	40	5	469.17	4.05	0.5	0.1
48	50	5	619.07	7.92	0.5	0.1
48	60	5	776.80	8.01	0.5	0.1
48	70	5	928.07	14.00	0.5	0.1
48	80	5	1109.17	13.36	0.5	0.1
48	90	5	1255.00	17.05	0.5	0.1

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	40	5	427.23	14.45	0.5	0.5
48	50	5	532.47	18.79	0.5	0.5
48	60	5	644.93	23.43	0.5	0.5
48	70	5	765.53	27.50	0.5	0.5
48	80	5	882.37	31.02	0.5	0.5
48	90	5	991.37	35.28	0.5	0.5
48	40	5	416.33	13.97	0.5	0.9
48	50	5	524.87	17.35	0.5	0.9
48	60	5	639.53	24.70	0.5	0.9
48	70	5	741.83	29.31	0.5	0.9
48	80	5	842.90	34.53	0.5	0.9
48	90	5	954.73	36.98	0.5	0.9
48	40	5	454.70	2.29	0.9	0.1
48	50	5	619.93	6.29	0.9	0.1
48	60	5	774.63	10.05	0.9	0.1
48	70	5	945.00	11.04	0.9	0.1
48	80	5	1145.43	12.79	0.9	0.1
48	90	5	1279.73	17.04	0.9	0.1
48	40	5	417.27	11.06	0.9	0.5
48	50	5	533.77	18.96	0.9	0.5
48	60	5	640.40	22.78	0.9	0.5
48	70	5	756.93	28.16	0.9	0.5
48	80	5	867.13	31.59	0.9	0.5
48	90	5	984.63	35.15	0.9	0.5
48	40	5	417.27	14.88	0.9	0.9
48	50	5	522.90	20.56	0.9	0.9
48	60	5	633.40	26.32	0.9	0.9
48	70	5	745.83	30.66	0.9	0.9
48	80	5	852.07	33.09	0.9	0.9
48	90	5	953.77	36.26	0.9	0.9
48	40	6	487.27	1.54	0.1	0.1
48	50	6	634.60	3.47	0.1	0.1
48	60	6	802.07	5.13	0.1	0.1
48	70	6	1021.53	4.10	0.1	0.1
48	80	6	1226.83	5.10	0.1	0.1
48	90	6	1455.50	4.15	0.1	0.1
48	40	6	434.27	8.24	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	50	6	569.27	13.86	0.1	0.5
48	60	6	680.63	17.53	0.1	0.5
48	70	6	822.73	22.04	0.1	0.5
48	80	6	987.50	23.51	0.1	0.5
48	90	6	1130.80	26.34	0.1	0.5
48	40	6	453.13	9.61	0.1	0.9
48	50	6	556.50	12.69	0.1	0.9
48	60	6	681.80	18.63	0.1	0.9
48	70	6	837.50	23.58	0.1	0.9
48	80	6	956.70	26.28	0.1	0.9
48	90	6	1084.27	28.63	0.1	0.9
48	40	6	477.77	2.29	0.5	0.1
48	50	6	628.50	6.52	0.5	0.1
48	60	6	780.20	7.60	0.5	0.1
48	70	6	974.53	9.69	0.5	0.1
48	80	6	1126.47	12.01	0.5	0.1
48	90	6	1328.57	12.18	0.5	0.1
48	40	6	433.77	13.14	0.5	0.5
48	50	6	540.03	17.64	0.5	0.5
48	60	6	655.73	22.15	0.5	0.5
48	70	6	776.27	26.48	0.5	0.5
48	80	6	897.93	29.80	0.5	0.5
48	90	6	1024.70	33.10	0.5	0.5
48	40	6	421.23	12.96	0.5	0.9
48	50	6	530.27	16.50	0.5	0.9
48	60	6	650.50	23.40	0.5	0.9
48	70	6	750.13	28.52	0.5	0.9
48	80	6	862.93	32.97	0.5	0.9
48	90	6	978.40	35.42	0.5	0.9
48	40	6	449.03	3.51	0.9	0.1
48	50	6	624.30	5.63	0.9	0.1
48	60	6	781.27	9.28	0.9	0.1
48	70	6	927.77	12.66	0.9	0.1
48	80	6	1137.93	13.36	0.9	0.1
48	90	6	1271.37	17.58	0.9	0.1
48	40	6	420.20	10.44	0.9	0.5
48	50	6	538.30	18.27	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	60	6	646.20	22.08	0.9	0.5
48	70	6	764.50	27.44	0.9	0.5
48	80	6	882.87	30.34	0.9	0.5
48	90	6	1009.37	33.52	0.9	0.5
48	40	6	420.60	14.20	0.9	0.9
48	50	6	533.70	18.92	0.9	0.9
48	60	6	638.27	25.76	0.9	0.9
48	70	6	752.10	30.08	0.9	0.9
48	80	6	858.10	32.62	0.9	0.9
48	90	6	965.40	35.48	0.9	0.9
48	40	7	483.40	2.32	0.1	0.1
48	50	7	632.83	3.74	0.1	0.1
48	60	7	802.73	5.05	0.1	0.1
48	70	7	1016.93	4.53	0.1	0.1
48	80	7	1241.30	3.98	0.1	0.1
48	90	7	1442.20	5.03	0.1	0.1
48	40	7	423.23	10.57	0.1	0.5
48	50	7	559.37	15.36	0.1	0.5
48	60	7	674.63	18.25	0.1	0.5
48	70	7	826.77	21.66	0.1	0.5
48	80	7	966.67	25.13	0.1	0.5
48	90	7	1105.17	28.01	0.1	0.5
48	40	7	464.63	7.31	0.1	0.9
48	50	7	571.13	10.40	0.1	0.9
48	60	7	710.33	15.23	0.1	0.9
48	70	7	850.00	22.44	0.1	0.9
48	80	7	984.73	24.12	0.1	0.9
48	90	7	1096.03	27.86	0.1	0.9
48	40	7	476.90	2.47	0.5	0.1
48	50	7	636.93	5.27	0.5	0.1
48	60	7	790.30	6.41	0.5	0.1
48	70	7	976.13	9.54	0.5	0.1
48	80	7	1152.47	9.98	0.5	0.1
48	90	7	1323.60	12.51	0.5	0.1
48	40	7	443.60	11.17	0.5	0.5
48	50	7	542.67	17.24	0.5	0.5
48	60	7	672.60	20.15	0.5	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	70	7	798.57	24.37	0.5	0.5
48	80	7	916.70	28.33	0.5	0.5
48	90	7	1027.50	32.92	0.5	0.5
48	40	7	434.37	10.24	0.5	0.9
48	50	7	543.90	14.35	0.5	0.9
48	60	7	660.20	22.26	0.5	0.9
48	70	7	776.67	25.99	0.5	0.9
48	80	7	885.43	31.22	0.5	0.9
48	90	7	1004.20	33.71	0.5	0.9
48	40	7	454.60	2.31	0.9	0.1
48	50	7	616.73	6.77	0.9	0.1
48	60	7	787.27	8.58	0.9	0.1
48	70	7	946.80	10.87	0.9	0.1
48	80	7	1165.57	11.26	0.9	0.1
48	90	7	1272.87	17.49	0.9	0.1
48	40	7	426.37	9.12	0.9	0.5
48	50	7	539.43	18.10	0.9	0.5
48	60	7	649.47	21.68	0.9	0.5
48	70	7	763.90	27.49	0.9	0.5
48	80	7	882.80	30.35	0.9	0.5
48	90	7	1005.00	33.81	0.9	0.5
48	40	7	429.63	12.36	0.9	0.9
48	50	7	539.90	17.98	0.9	0.9
48	60	7	650.40	24.35	0.9	0.9
48	70	7	768.37	28.57	0.9	0.9
48	80	7	874.37	31.34	0.9	0.9
48	90	7	987.90	33.98	0.9	0.9
48	40	8	485.47	1.91	0.1	0.1
48	50	8	636.13	3.24	0.1	0.1
48	60	8	808.00	4.42	0.1	0.1
48	70	8	1017.57	4.47	0.1	0.1
48	80	8	1235.27	4.44	0.1	0.1
48	90	8	1453.30	4.30	0.1	0.1
48	40	8	437.03	7.66	0.1	0.5
48	50	8	572.77	13.33	0.1	0.5
48	60	8	694.23	15.88	0.1	0.5
48	70	8	836.57	20.73	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	80	8	992.10	23.16	0.1	0.5
48	90	8	1115.27	27.35	0.1	0.5
48	40	8	473.00	5.65	0.1	0.9
48	50	8	579.77	9.04	0.1	0.9
48	60	8	727.27	13.21	0.1	0.9
48	70	8	874.17	20.23	0.1	0.9
48	80	8	1012.50	21.98	0.1	0.9
48	90	8	1130.70	25.57	0.1	0.9
48	40	8	478.17	2.21	0.5	0.1
48	50	8	623.50	7.26	0.5	0.1
48	60	8	783.23	7.24	0.5	0.1
48	70	8	973.73	9.76	0.5	0.1
48	80	8	1134.40	11.39	0.5	0.1
48	90	8	1327.33	12.27	0.5	0.1
48	40	8	445.47	10.79	0.5	0.5
48	50	8	547.17	16.55	0.5	0.5
48	60	8	670.93	20.35	0.5	0.5
48	70	8	790.83	25.10	0.5	0.5
48	80	8	909.73	28.88	0.5	0.5
48	90	8	1026.47	32.99	0.5	0.5
48	40	8	439.43	9.20	0.5	0.9
48	50	8	555.03	12.60	0.5	0.9
48	60	8	676.90	20.30	0.5	0.9
48	70	8	791.90	24.54	0.5	0.9
48	80	8	910.37	29.29	0.5	0.9
48	90	8	1041.97	31.22	0.5	0.9
48	40	8	456.90	1.82	0.9	0.1
48	50	8	620.60	6.19	0.9	0.1
48	60	8	786.80	8.64	0.9	0.1
48	70	8	946.47	10.90	0.9	0.1
48	80	8	1155.77	12.01	0.9	0.1
48	90	8	1288.87	16.45	0.9	0.1
48	40	8	423.63	9.71	0.9	0.5
48	50	8	537.37	18.41	0.9	0.5
48	60	8	655.73	20.93	0.9	0.5
48	70	8	766.20	27.28	0.9	0.5
48	80	8	885.33	30.15	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
48	90	8	1006.73	33.69	0.9	0.5
48	40	8	428.87	12.52	0.9	0.9
48	50	8	540.40	17.91	0.9	0.9
48	60	8	657.60	23.51	0.9	0.9
48	70	8	770.27	28.39	0.9	0.9
48	80	8	876.23	31.19	0.9	0.9
48	90	8	990.30	33.82	0.9	0.9

HORIZONTE DE 72H

Tabela 12 – Resultados médios para horizonte de 72h

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	40	5	453.00	0.52	0.1	0.1
72	50	5	578.83	2.24	0.1	0.1
72	60	5	737.63	3.19	0.1	0.1
72	70	5	886.47	5.75	0.1	0.1
72	80	5	1080.73	7.59	0.1	0.1
72	90	5	1306.77	7.10	0.1	0.1
72	40	5	415.03	8.92	0.1	0.5
72	50	5	530.43	13.23	0.1	0.5
72	60	5	624.80	16.83	0.1	0.5
72	70	5	729.27	20.47	0.1	0.5
72	80	5	847.33	27.24	0.1	0.5
72	90	5	961.30	34.34	0.1	0.5
72	40	5	415.63	8.62	0.1	0.9
72	50	5	527.73	13.45	0.1	0.9
72	60	5	625.80	16.66	0.1	0.9
72	70	5	731.27	23.60	0.1	0.9
72	80	5	841.33	27.39	0.1	0.9
72	90	5	954.07	33.56	0.1	0.9
72	40	5	448.53	1.59	0.5	0.1
72	50	5	592.63	1.90	0.5	0.1
72	60	5	747.67	3.16	0.5	0.1
72	70	5	896.13	7.44	0.5	0.1
72	80	5	1098.10	11.06	0.5	0.1
72	90	5	1218.20	13.73	0.5	0.1

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	40	5	419.23	5.81	0.5	0.5
72	50	5	530.47	11.45	0.5	0.5
72	60	5	634.43	17.42	0.5	0.5
72	70	5	758.90	22.84	0.5	0.5
72	80	5	864.20	27.77	0.5	0.5
72	90	5	983.50	33.32	0.5	0.5
72	40	5	418.57	9.41	0.5	0.9
72	50	5	520.63	11.62	0.5	0.9
72	60	5	620.80	18.12	0.5	0.9
72	70	5	740.30	25.28	0.5	0.9
72	80	5	849.40	29.51	0.5	0.9
72	90	5	953.77	34.67	0.5	0.9
72	40	5	452.07	-0.08	0.9	0.1
72	50	5	594.13	2.45	0.9	0.1
72	60	5	758.93	2.24	0.9	0.1
72	70	5	885.73	6.54	0.9	0.1
72	80	5	1068.90	8.18	0.9	0.1
72	90	5	1240.37	10.88	0.9	0.1
72	40	5	425.57	7.73	0.9	0.5
72	50	5	522.70	11.92	0.9	0.5
72	60	5	636.53	17.49	0.9	0.5
72	70	5	744.40	21.77	0.9	0.5
72	80	5	865.83	27.95	0.9	0.5
72	90	5	971.97	33.38	0.9	0.5
72	40	5	416.17	7.57	0.9	0.9
72	50	5	515.63	13.38	0.9	0.9
72	60	5	624.67	18.40	0.9	0.9
72	70	5	731.50	23.84	0.9	0.9
72	80	5	842.90	27.24	0.9	0.9
72	90	5	950.97	34.81	0.9	0.9
72	40	6	455.83	-0.10	0.1	0.1
72	50	6	585.17	1.17	0.1	0.1
72	60	6	754.53	0.97	0.1	0.1
72	70	6	907.47	3.52	0.1	0.1
72	80	6	1111.77	4.94	0.1	0.1
72	90	6	1326.63	5.69	0.1	0.1
72	40	6	425.00	6.73	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	50	6	544.07	11.00	0.1	0.5
72	60	6	657.80	12.44	0.1	0.5
72	70	6	783.47	14.56	0.1	0.5
72	80	6	928.60	20.26	0.1	0.5
72	90	6	1088.93	25.62	0.1	0.5
72	40	6	430.40	5.37	0.1	0.9
72	50	6	552.00	9.47	0.1	0.9
72	60	6	660.43	12.05	0.1	0.9
72	70	6	794.43	17.00	0.1	0.9
72	80	6	908.40	21.60	0.1	0.9
72	90	6	1049.13	26.94	0.1	0.9
72	40	6	449.93	1.29	0.5	0.1
72	50	6	596.67	1.23	0.5	0.1
72	60	6	754.07	2.33	0.5	0.1
72	70	6	924.60	4.50	0.5	0.1
72	80	6	1112.33	9.90	0.5	0.1
72	90	6	1272.23	9.90	0.5	0.1
72	40	6	419.67	5.71	0.5	0.5
72	50	6	529.93	11.54	0.5	0.5
72	60	6	641.40	16.52	0.5	0.5
72	70	6	777.50	20.95	0.5	0.5
72	80	6	876.53	26.74	0.5	0.5
72	90	6	995.33	32.52	0.5	0.5
72	40	6	415.47	10.08	0.5	0.9
72	50	6	521.57	11.46	0.5	0.9
72	60	6	624.07	17.69	0.5	0.9
72	70	6	748.10	24.50	0.5	0.9
72	80	6	861.43	28.52	0.5	0.9
72	90	6	971.83	33.43	0.5	0.9
72	40	6	447.57	0.91	0.9	0.1
72	50	6	591.03	2.96	0.9	0.1
72	60	6	752.63	3.05	0.9	0.1
72	70	6	871.23	8.07	0.9	0.1
72	80	6	1059.70	8.97	0.9	0.1
72	90	6	1239.67	10.93	0.9	0.1
72	40	6	422.23	8.46	0.9	0.5
72	50	6	526.07	11.35	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	60	6	640.47	16.98	0.9	0.5
72	70	6	746.90	21.51	0.9	0.5
72	80	6	869.50	27.65	0.9	0.5
72	90	6	989.63	32.17	0.9	0.5
72	40	6	418.60	7.03	0.9	0.9
72	50	6	521.17	12.45	0.9	0.9
72	60	6	633.30	17.27	0.9	0.9
72	70	6	741.80	22.77	0.9	0.9
72	80	6	854.83	26.21	0.9	0.9
72	90	6	965.17	33.83	0.9	0.9
72	40	7	454.47	0.20	0.1	0.1
72	50	7	576.17	2.69	0.1	0.1
72	60	7	750.37	1.52	0.1	0.1
72	70	7	912.03	3.03	0.1	0.1
72	80	7	1103.40	5.65	0.1	0.1
72	90	7	1319.67	6.18	0.1	0.1
72	40	7	418.67	8.12	0.1	0.5
72	50	7	541.43	11.43	0.1	0.5
72	60	7	648.60	13.66	0.1	0.5
72	70	7	771.93	15.82	0.1	0.5
72	80	7	915.37	21.40	0.1	0.5
72	90	7	1068.00	27.05	0.1	0.5
72	40	7	444.73	2.22	0.1	0.9
72	50	7	575.50	5.62	0.1	0.9
72	60	7	687.20	8.48	0.1	0.9
72	70	7	818.37	14.50	0.1	0.9
72	80	7	930.40	19.70	0.1	0.9
72	90	7	1078.73	24.88	0.1	0.9
72	40	7	449.80	1.32	0.5	0.1
72	50	7	602.83	0.21	0.5	0.1
72	60	7	749.43	2.93	0.5	0.1
72	70	7	922.43	4.73	0.5	0.1
72	80	7	1129.87	8.48	0.5	0.1
72	90	7	1277.63	9.52	0.5	0.1
72	40	7	421.10	5.39	0.5	0.5
72	50	7	538.20	10.15	0.5	0.5
72	60	7	655.33	14.70	0.5	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	70	7	791.93	19.48	0.5	0.5
72	80	7	885.90	25.95	0.5	0.5
72	90	7	1027.53	30.34	0.5	0.5
72	40	7	427.00	7.58	0.5	0.9
72	50	7	534.33	9.30	0.5	0.9
72	60	7	634.50	16.31	0.5	0.9
72	70	7	770.10	22.27	0.5	0.9
72	80	7	884.83	26.57	0.5	0.9
72	90	7	989.33	32.24	0.5	0.9
72	40	7	451.87	-0.04	0.9	0.1
72	50	7	589.70	3.17	0.9	0.1
72	60	7	757.27	2.46	0.9	0.1
72	70	7	881.60	6.97	0.9	0.1
72	80	7	1076.20	7.55	0.9	0.1
72	90	7	1249.10	10.25	0.9	0.1
72	40	7	429.90	6.79	0.9	0.5
72	50	7	530.33	10.63	0.9	0.5
72	60	7	648.93	15.88	0.9	0.5
72	70	7	754.20	20.74	0.9	0.5
72	80	7	881.13	26.68	0.9	0.5
72	90	7	993.70	31.89	0.9	0.5
72	40	7	427.70	5.01	0.9	0.9
72	50	7	528.90	11.15	0.9	0.9
72	60	7	643.57	15.93	0.9	0.9
72	70	7	753.23	21.58	0.9	0.9
72	80	7	867.63	25.11	0.9	0.9
72	90	7	981.97	32.68	0.9	0.9
72	40	8	453.33	0.45	0.1	0.1
72	50	8	579.20	2.17	0.1	0.1
72	60	8	739.57	2.93	0.1	0.1
72	70	8	894.70	4.88	0.1	0.1
72	80	8	1101.50	5.81	0.1	0.1
72	90	8	1315.03	6.51	0.1	0.1
72	40	8	428.00	6.07	0.1	0.5
72	50	8	556.73	8.93	0.1	0.5
72	60	8	674.23	10.25	0.1	0.5
72	70	8	783.07	14.61	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	80	8	929.07	20.22	0.1	0.5
72	90	8	1085.53	25.85	0.1	0.5
72	40	8	446.50	1.83	0.1	0.9
72	50	8	576.30	5.49	0.1	0.9
72	60	8	692.90	7.72	0.1	0.9
72	70	8	827.67	13.53	0.1	0.9
72	80	8	953.77	17.68	0.1	0.9
72	90	8	1119.27	22.06	0.1	0.9
72	40	8	446.03	2.14	0.5	0.1
72	50	8	592.67	1.89	0.5	0.1
72	60	8	744.77	3.54	0.5	0.1
72	70	8	902.63	6.77	0.5	0.1
72	80	8	1123.17	9.03	0.5	0.1
72	90	8	1284.07	9.06	0.5	0.1
72	40	8	427.93	3.85	0.5	0.5
72	50	8	538.27	10.14	0.5	0.5
72	60	8	656.80	14.51	0.5	0.5
72	70	8	779.93	20.70	0.5	0.5
72	80	8	895.87	25.12	0.5	0.5
72	90	8	1025.50	30.47	0.5	0.5
72	40	8	442.00	4.34	0.5	0.9
72	50	8	545.97	7.32	0.5	0.9
72	60	8	655.77	13.51	0.5	0.9
72	70	8	781.57	21.12	0.5	0.9
72	80	8	908.07	24.65	0.5	0.9
72	90	8	1017.17	30.33	0.5	0.9
72	40	8	447.43	0.95	0.9	0.1
72	50	8	587.47	3.54	0.9	0.1
72	60	8	745.50	3.97	0.9	0.1
72	70	8	877.83	7.37	0.9	0.1
72	80	8	1074.50	7.70	0.9	0.1
72	90	8	1251.63	10.07	0.9	0.1
72	40	8	424.53	7.96	0.9	0.5
72	50	8	529.10	10.84	0.9	0.5
72	60	8	639.60	17.09	0.9	0.5
72	70	8	745.63	21.64	0.9	0.5
72	80	8	873.93	27.28	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
72	90	8	993.03	31.94	0.9	0.5
72	40	8	427.70	5.01	0.9	0.9
72	50	8	528.93	11.15	0.9	0.9
72	60	8	642.70	16.04	0.9	0.9
72	70	8	754.13	21.48	0.9	0.9
72	80	8	874.07	24.55	0.9	0.9
72	90	8	985.07	32.47	0.9	0.9

HORIZONTE DE 168H

Tabela 13 – Resultados médios para horizonte de 168h

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
168	100	5	1159.70	3.48	0.1	0.1
168	125	5	1585.70	6.66	0.1	0.1
168	150	5	2042.73	9.75	0.1	0.1
168	175	5	2698.23	13.79	0.1	0.1
168	200	5	3474.43	17.28	0.1	0.1
168	100	5	1037.73	14.08	0.1	0.5
168	125	5	1313.63	21.48	0.1	0.5
168	150	5	1577.23	31.48	0.1	0.5
168	175	5	1844.40	42.35	0.1	0.5
168	200	5	2127.60	50.44	0.1	0.5
168	100	5	1037.50	13.33	0.1	0.9
168	125	5	1297.33	22.84	0.1	0.9
168	150	5	1570.23	33.99	0.1	0.9
168	175	5	1835.83	42.12	0.1	0.9
168	200	5	2114.47	48.76	0.1	0.9
168	100	5	1194.30	3.02	0.5	0.1
168	125	5	1589.23	5.40	0.5	0.1
168	150	5	2080.43	9.46	0.5	0.1
168	175	5	2581.70	18.44	0.5	0.1
168	200	5	3113.07	23.96	0.5	0.1
168	100	5	1055.10	12.55	0.5	0.5
168	125	5	1324.50	21.71	0.5	0.5
168	150	5	1611.10	30.82	0.5	0.5
168	175	5	1872.37	40.82	0.5	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
168	200	5	2172.67	49.40	0.5	0.5
168	100	5	1043.53	14.79	0.5	0.9
168	125	5	1308.43	22.68	0.5	0.9
168	150	5	1563.93	31.62	0.5	0.9
168	175	5	1838.97	41.87	0.5	0.9
168	200	5	2110.27	50.21	0.5	0.9
168	100	5	1195.60	2.53	0.9	0.1
168	125	5	1575.57	6.46	0.9	0.1
168	150	5	2054.90	11.91	0.9	0.1
168	175	5	2569.47	19.91	0.9	0.1
168	200	5	3162.07	26.37	0.9	0.1
168	100	5	1058.97	12.54	0.9	0.5
168	125	5	1325.27	21.62	0.9	0.5
168	150	5	1593.00	31.06	0.9	0.5
168	175	5	1877.40	42.10	0.9	0.5
168	200	5	2169.30	49.95	0.9	0.5
168	100	5	1043.53	16.89	0.9	0.9
168	125	5	1310.93	26.64	0.9	0.9
168	150	5	1572.67	31.64	0.9	0.9
168	175	5	1842.47	42.43	0.9	0.9
168	200	5	2110.50	48.99	0.9	0.9
168	100	6	1181.43	1.67	0.1	0.1
168	125	6	1627.97	4.17	0.1	0.1
168	150	6	2109.43	6.81	0.1	0.1
168	175	6	2794.90	10.70	0.1	0.1
168	200	6	3709.13	11.69	0.1	0.1
168	100	6	1070.97	11.33	0.1	0.5
168	125	6	1380.67	17.47	0.1	0.5
168	150	6	1707.20	25.83	0.1	0.5
168	175	6	2150.43	32.78	0.1	0.5
168	200	6	2490.40	41.99	0.1	0.5
168	100	6	1080.10	9.77	0.1	0.9
168	125	6	1369.77	18.53	0.1	0.9
168	150	6	1695.23	28.74	0.1	0.9
168	175	6	2015.17	36.47	0.1	0.9
168	200	6	2329.83	43.54	0.1	0.9
168	100	6	1195.73	2.90	0.5	0.1

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
168	125	6	1597.60	4.90	0.5	0.1
168	150	6	2108.03	8.26	0.5	0.1
168	175	6	2695.40	14.84	0.5	0.1
168	200	6	3267.97	20.18	0.5	0.1
168	100	6	1056.53	12.43	0.5	0.5
168	125	6	1348.40	20.29	0.5	0.5
168	150	6	1634.20	29.83	0.5	0.5
168	175	6	1915.93	39.44	0.5	0.5
168	200	6	2214.40	48.43	0.5	0.5
168	100	6	1044.60	14.71	0.5	0.9
168	125	6	1312.50	22.44	0.5	0.9
168	150	6	1575.30	31.12	0.5	0.9
168	175	6	1861.27	41.17	0.5	0.9
168	200	6	2152.77	49.21	0.5	0.9
168	100	6	1193.10	2.73	0.9	0.1
168	125	6	1564.97	7.09	0.9	0.1
168	150	6	2081.53	10.77	0.9	0.1
168	175	6	2618.03	18.39	0.9	0.1
168	200	6	3067.70	28.57	0.9	0.1
168	100	6	1051.17	13.19	0.9	0.5
168	125	6	1322.10	21.81	0.9	0.5
168	150	6	1593.90	31.02	0.9	0.5
168	175	6	1891.57	41.66	0.9	0.5
168	200	6	2182.37	49.65	0.9	0.5
168	100	6	1053.87	16.07	0.9	0.9
168	125	6	1323.30	25.95	0.9	0.9
168	150	6	1593.50	30.73	0.9	0.9
168	175	6	1867.27	41.66	0.9	0.9
168	200	6	2138.33	48.32	0.9	0.9
168	100	7	1158.80	3.55	0.1	0.1
168	125	7	1616.83	4.83	0.1	0.1
168	150	7	2073.87	8.38	0.1	0.1
168	175	7	2708.63	13.46	0.1	0.1
168	200	7	3592.23	14.47	0.1	0.1
168	100	7	1062.10	12.06	0.1	0.5
168	125	7	1358.40	18.80	0.1	0.5
168	150	7	1668.47	27.51	0.1	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
168	175	7	2047.50	36.00	0.1	0.5
168	200	7	2420.47	43.62	0.1	0.5
168	100	7	1126.07	5.93	0.1	0.9
168	125	7	1408.53	16.23	0.1	0.9
168	150	7	1732.13	27.19	0.1	0.9
168	175	7	2048.73	35.41	0.1	0.9
168	200	7	2372.07	42.51	0.1	0.9
168	100	7	1218.33	1.06	0.5	0.1
168	125	7	1616.43	3.78	0.5	0.1
168	150	7	2098.23	8.68	0.5	0.1
168	175	7	2681.70	15.28	0.5	0.1
168	200	7	3238.77	20.89	0.5	0.1
168	100	7	1071.33	11.21	0.5	0.5
168	125	7	1364.13	19.36	0.5	0.5
168	150	7	1658.10	28.81	0.5	0.5
168	175	7	1963.83	37.92	0.5	0.5
168	200	7	2261.13	47.34	0.5	0.5
168	100	7	1063.93	13.13	0.5	0.9
168	125	7	1343.53	20.61	0.5	0.9
168	150	7	1618.00	29.25	0.5	0.9
168	175	7	1918.00	39.38	0.5	0.9
168	200	7	2210.70	47.84	0.5	0.9
168	100	7	1203.67	1.87	0.9	0.1
168	125	7	1575.17	6.48	0.9	0.1
168	150	7	2117.10	9.25	0.9	0.1
168	175	7	2578.67	19.62	0.9	0.1
168	200	7	3133.60	27.04	0.9	0.1
168	100	7	1071.97	11.47	0.9	0.5
168	125	7	1345.60	20.42	0.9	0.5
168	150	7	1614.47	30.13	0.9	0.5
168	175	7	1912.83	41.00	0.9	0.5
168	200	7	2202.67	49.18	0.9	0.5
168	100	7	1069.23	14.84	0.9	0.9
168	125	7	1348.17	24.56	0.9	0.9
168	150	7	1618.40	29.65	0.9	0.9
168	175	7	1897.70	40.71	0.9	0.9
168	200	7	2182.40	47.25	0.9	0.9

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
168	100	8	1165.83	2.97	0.1	0.1
168	125	8	1611.77	5.12	0.1	0.1
168	150	8	2052.37	9.33	0.1	0.1
168	175	8	2782.27	11.11	0.1	0.1
168	200	8	3623.10	13.74	0.1	0.1
168	100	8	1074.80	11.01	0.1	0.5
168	125	8	1388.53	17.00	0.1	0.5
168	150	8	1712.33	25.61	0.1	0.5
168	175	8	2100.80	34.33	0.1	0.5
168	200	8	2500.13	41.77	0.1	0.5
168	100	8	1129.27	5.67	0.1	0.9
168	125	8	1429.87	14.96	0.1	0.9
168	150	8	1783.87	25.01	0.1	0.9
168	175	8	2107.50	33.56	0.1	0.9
168	200	8	2462.33	40.32	0.1	0.9
168	100	8	1191.73	3.22	0.5	0.1
168	125	8	1585.87	5.60	0.5	0.1
168	150	8	2092.37	8.94	0.5	0.1
168	175	8	2662.57	15.88	0.5	0.1
168	200	8	3244.27	20.76	0.5	0.1
168	100	8	1078.93	10.58	0.5	0.5
168	125	8	1372.77	18.85	0.5	0.5
168	150	8	1663.70	28.57	0.5	0.5
168	175	8	1946.63	38.47	0.5	0.5
168	200	8	2272.73	47.07	0.5	0.5
168	100	8	1106.70	9.64	0.5	0.9
168	125	8	1375.10	18.75	0.5	0.9
168	150	8	1667.90	27.07	0.5	0.9
168	175	8	1975.07	37.57	0.5	0.9
168	200	8	2266.73	46.52	0.5	0.9
168	100	8	1192.17	2.81	0.9	0.1
168	125	8	1614.27	4.16	0.9	0.1
168	150	8	2074.83	11.06	0.9	0.1
168	175	8	2612.63	18.56	0.9	0.1
168	200	8	3204.67	25.38	0.9	0.1
168	100	8	1054.87	12.88	0.9	0.5
168	125	8	1326.77	21.53	0.9	0.5

Horas	Navios	Clusters	Custo Médio	Redução (%)	α	γ
168	150	8	1599.90	30.76	0.9	0.5
168	175	8	1905.47	41.23	0.9	0.5
168	200	8	2201.00	49.22	0.9	0.5
168	100	8	1067.20	15.00	0.9	0.9
168	125	8	1349.73	24.47	0.9	0.9
168	150	8	1628.57	29.21	0.9	0.9
168	175	8	1906.60	40.43	0.9	0.9
168	200	8	2185.87	47.17	0.9	0.9