



PLANEJAMENTO DE ENTREGAS DE SUPRIMENTOS OFFSHORE COM EMBARCAÇÕES MULTIPRODUTO

Rennan Danilo Seimetz Chagas

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

Orientador: Vírgilio José Martins Ferreira
Filho

Rio de Janeiro
Setembro de 2022

PLANEJAMENTO DE ENTREGAS DE SUPRIMENTOS OFFSHORE COM
EMBARCAÇÕES MULTIPRODUTO

Rennan Danilo Seimetz Chagas

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

Examinada por:

Prof. Vírgilio José Martins Ferreira Filho, D.Sc.

Prof. Lino Guimarães Marujo, D.Sc.

Prof. Glaydston Mattos Ribeiro, D.Sc.

Prof. Luiz Satoru Ochi, D.Sc.

Prof. Paulo Cesar Ribas, D.Sc.

Prof. Reinaldo Morabito Neto, D.Sc.

RIO DE JANEIRO, RJ – BRASIL
SETEMBRO DE 2022

Seimetz Chagas, Rennan Danilo

Planejamento de Entregas de Suprimentos Offshore com Embarcações Multiproduto/Rennan Danilo Seimetz Chagas. – Rio de Janeiro: UFRJ/COPPE, 2022.

XII, 96 p.: il.; 29,7cm.

Orientador: Vírgilio José Martins Ferreira Filho

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia de Produção, 2022.

Referências Bibliográficas: p. 73 – 85.

1. Primeira palavra-chave. 2. Segunda palavra-chave. 3. Terceira palavra-chave. I. Ferreira Filho, Vírgilio José Martins. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Produção. III. Título.

*À minha nona, Olinda Seimetz
(in memoriam), que colecionava
todos meus diplomas. Durante
meu intercâmbio partiu sem
poder levar este último.*

Agradecimentos

Aos meus pais, Zulmira e Danilo, pela dedicação, todo incentivo que sempre me deram com relação aos estudos e por todos os castigos que precisei até aprender a tabuada. Tudo o que fizeram permitiu que eu pudesse chegar até aqui. Pai, agora somos colegas doutores.

Ao meu orientador, Virgílio, por todos os conselhos e paciência na elaboração da pesquisa e por proporcionar um ambiente tão bom como o LORDE para desenvolvimento de pesquisas e projetos. Eu o vejo, além de um mentor, como um exemplo de profissional e um grande amigo.

Aos professores Lino Guimarães, Glaydston Ribeiro, Luiz Satoru, Paulo Ribas e Reinaldo Morabito por aceitarem participar da banca de avaliação deste trabalho.

Aos colegas e amigos que fiz ao longo desses anos no LORDE e na UFRJ. Em especial Gustavo e Rafael, que sei que têm por mim, assim como eu por eles, o carinho de irmãos. Além deles, agradeço também aos amigos Clara, Danielle, Gabriela, Girão, Luciana, Thonny e Victor com quem compartilhei tantos dias, noites, pizzas, churrascos, festas juninas e boas conversas.

Ao Professor Gilbert Laporte por me receber em Montreal durante o intercâmbio sanduíche e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) que financiou esse empreendimento. A experiência de trabalhar em um centro de pesquisa como o CIRRELT e poder viver em outro país tão diferente (-30^o C de diferença) como o Canadá, não serviu apenas amadurecimento desta tese, mas também para o meu desenvolvimento como pessoa.

A toda equipe de servidores e funcionários da COPPE, PEP e SAGE fundamentais para manutenção de toda a infraestrutura da pós-graduação e do laboratório.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) e a Petrobras pelo auxílio financeiro. Produzir e divulgar conhecimento custa caro, e o financiamento foi muito importante para viabilizar a elaboração deste trabalho e seus artigos.

E a todos os parentes e amigos que durante meu doutorado me motivaram a continuar, me ajudaram quando precisei e foram pacientes com minhas ausências.

*Sapientiam autem
non vincit malitia*

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

PLANEJAMENTO DE ENTREGAS DE SUPRIMENTOS OFFSHORE COM EMBARCAÇÕES MULTIPRODUTO

Rennan Danilo Seimetz Chagas

Setembro/2022

Orientador: Vírgilio José Martins Ferreira Filho

Programa: Engenharia de Produção

As atividades de exploração e produção de óleo e gás (E&P) no setor *offshore*, especificamente na camada pré-sal, têm imposto grandes desafios relacionados não apenas a tecnologias voltadas para engenharia de petróleo, mas também, ligados às áreas de logística, gestão de operações e infraestrutura fundamentais para a continuidade operacional em E&P. Comumente, o transporte marítimo é realizado por embarcações do tipo *Platform Supply Vessels* (PSVs). A literatura sobre o planejamento de operações PSV é rica, mas poucos estudos se concentraram no problema da seleção de pedidos. Nesta tese é apresentada uma formulação para o Problema de Alocação de Cargas Marítimas com Embarcações Multiproduto, a qual consiste em definir a programação das cargas com foco específico nos pedidos de entrega. Por programação entenda-se a alocação desses pedidos a um conjunto de viagens que utiliza um PSV para transporte observando aspectos tais como: (i) a demanda e os prazos dos pedidos; (ii) as viagens previstas para os grupos de plataformas; e (iii) os PSVs disponíveis. O nosso estudo apresenta soluções com qualidade verificada com a utilização de um simulador, que podem melhorar os níveis de serviço, reduzindo as necessidades da frota, os custos operacionais e as emissões. Os experimentos mostraram que o problema matemático é de difícil resolução e, por este motivo, foram comparados os resultados gerados por este modelo com os obtidos por métodos heurísticos e metaheurísticos. Ao fim, são apresentadas as considerações gerais sobre a tese e uma coletânea dos trabalhos acadêmicos derivados dela.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

PLANNING OFFSHORE SUPPLY DELIVERIES WITH MULTIPRODUCT VESSELS

Rennan Danilo Seimetz Chagas

September/2022

Advisor: Vírgilio José Martins Ferreira Filho

Department: Production Engineering

Oil and gas (E&P) exploration and production activities in the offshore sector, specifically in the pre-salt region, have imposed major challenges related not only to petroleum engineering technologies but also to the logistics, resources and infrastructures management, fundamental for the operational continuity in E&P operations. Commonly, maritime transport is carried out by Platform Supply Vessels (PSVs). The literature on PSV operations planning is rich, but few studies have focused on the order selection problem. In this work, we present a formulation for an order selection problem. In this thesis we present a formulation for the Problem of Allocation of Maritime Cargo with Multiproduct Vessels, which consists of defining cargo planning, with specific focus on the delivery requests. By planning, it is understood to allocate these requests to a set of trips, which uses a PSV for transportation observing aspects such as: (i) the demand and deadlines of the requests; (ii) the planned trips to the platform clusters; and (iii) available PSVs. Our study presents good quality solutions, verified using a simulation tool, that can improve service levels while reducing fleet requirements, operating costs, and emissions. The experiments showed that the mathematical problem is difficult to solve and, for this reason, the results generated by this model were compared with the ones obtained by heuristic and metaheuristic methods. At the end, general considerations about the thesis and a collection of the academic papers derived from it are presented.

Sumário

Lista de Figuras	xi
Lista de Tabelas	xii
1 Introdução	1
1.1 Relevância do tema	4
1.2 Objetivo	5
1.3 Estrutura do documento	5
2 O Problema de Alocação de Cargas Marítimas com Embarcações Multiproduto	7
2.1 Descrevendo o problema	8
2.2 Revisão bibliográfica	12
2.2.1 Problemas de Planejamento de Logística Upstream	12
2.2.2 Gestão de pedidos e planejamento de entregas	15
3 Estimando o impacto de uma boa gestão integrada de pedidos e frota	16
3.1 Modelo de simulação de eventos discretos	17
3.1.1 Operação Tipo A (PSVs portuário)	17
3.1.2 Operação Tipo B (Oleiros)	18
3.1.3 Estruturas do modelo de simulação	20
3.2 Estratégias de alocação	21
3.2.1 Estratégia de alocação first in, first out (FIFO)	21
3.2.2 Modelagem matemática	21
3.3 Experimentos computacionais	26
3.3.1 Validação do modelo proposto	27
3.3.2 Estudo de caso	30
3.3.3 Perspectivas gerenciais	33
3.3.4 Visão geral do desempenho computacional da metodologia	37
3.4 Conclusões	37

4	Um modelo tático de planejamento com múltiplas viagens	40
4.1	Formulação matemática com múltiplas viagens e geração de instâncias	40
4.1.1	Definições	41
4.1.2	Formulação matemática	41
4.2	Geração de instâncias	45
4.2.1	Geração de rotas	46
4.2.2	Geração de pedidos	47
4.2.3	Geração de barcos	48
4.3	Experimentos computacionais	48
4.4	Conclusões	49
5	Metaheurísticas e algoritmos híbridos	51
5.1	Estrutura de solução e vizinhança	51
5.2	Heurística construtiva Relax-and-Fix	53
5.3	Adaptive Large Neighborhood Search - ALNS	55
5.3.1	Construção da solução inicial	57
5.3.2	Operadores de destruição e reparação	58
5.4	Uma implementação ramificada do ALNS	60
5.5	Experimentos computacionais	61
5.5.1	Resultados obtidos com a heurística Relax-and-Fix	62
5.5.2	Resultados obtidos com a metaheurística ALNS	63
5.6	Conclusões	64
6	Considerações finais	69
6.1	Resultados academicos obtidos relacionados a tese	71
6.2	Trabalhos Futuros	72
	Referências Bibliográficas	73
A	Trabalhos publicados	86
A.1	L SBPO - 2018	87
A.2	Rio Oil & Gas - 2018	88
A.3	Computers & Industrial Engineering	89
A.4	Optimization and Engineering	90
B	Trabalhos submetidos em revisão	91
B.1	Computers & Industrial Engineering	92
C	Resultados completos dos experimentos com a metaheurística ALNS	93

Lista de Figuras

1.1	Unidades de produção e sondas em atividade <i>offshore</i> na Bacia de Campos e Santos no ano de 2016.	2
1.2	Rede logística <i>offshore</i>	3
2.1	Representação da operação com frota especialista.	10
2.2	Representação da operação com frota multiproduto.	11
3.1	Alocação de carga.	18
3.2	Operações no porto.	18
3.3	Operações de entrega de cargas.	18
3.4	Alocação de cargas para oleiros.	18
3.5	Operação de entrega do PSV oleiro.	19
3.6	Histogramas de nível de serviço para os quatro casos simulados.	30
3.7	Total de emissões versus nível de serviço.	34
3.8	Custo total versus nível de serviço.	34
3.9	Tamanho de frota vs nível de serviço.	36
3.10	Tempo computacional da otimização.	38
3.11	Tempo computacional da simulação.	38
4.1	Limitantes superior e inferior para cada instância vs tempo de processamento	50
5.1	Representação da Estrutura de solução	52
5.2	Representação da Estrutura de Vizinhança e Busca Local	53
5.3	Valor objetivo e tempos de CPU relativos da heurística <i>relax-and-fix</i> . Resultados do modelo matemático com linha base em 1.0	63
5.4	Distribuição empírica de probabilidade acumulada do GAP da solução obtida com as heurísticas aleatória e gulosa randomizada	66
5.5	Distribuição do GAP da solução obtida com as heurísticas aleatória e gulosa randomizada	67

Lista de Tabelas

2.1	Lista de pedidos.	12
2.2	Cronograma de viagens.	12
2.3	Frota disponível.	12
3.1	Notações utilizadas para conjuntos, parâmetros e variáveis do modelo matemático	22
3.2	Indicadores de desempenho (KPIs) selecionados para validação	28
3.3	Resultados da validação	28
3.4	Intevalos de confiança para 30 replicações.	29
3.5	Configuração do estudo de caso.	31
3.6	Principais indicadores de desempenho do cenário <i>benchmark</i> comparados com a Estratégia 1 com frota reduzida.	31
3.7	Estratégias avaliadas nos experimentos.	31
3.8	Indicadores de desempenho avaliados.	32
3.9	Resultados dos indicadores para todas as estratégias.	33
3.10	Resultados obtidos com frota mínima para atingir nível de serviço de 80%.	36
3.11	Resultados obtidos pelo modelo matemático.	37
4.1	Notação utilizada para conjuntos, parâmetros e variáveis de decisão .	41
4.2	Caracterização das instâncias.	45
4.3	Distribuições de probalidades das instâncias	46
4.4	Exemplo de conjunto de rotas para instâncias com 10 clientes, 4 rotas e dois clientes atendidos por rota	47
4.5	Resultados obtidos com o solver comercial para as 32 instâncias . . .	49
5.1	Resumo dos resultados obtidos pelo modelo matemático e pela heurística <i>relax-and-fix</i>	64
5.2	Valor esperado da razão entre melhor solução da metaheurística e melhor solução do modelo matemático.	65

Capítulo 1

Introdução

Bens e serviços são escassos e, devido sua escassez, faz-se necessário administrá-los de forma racional. Essa busca pela administração racional dos recursos promove os esforços em tornar os processos de transformação e prestação de serviços mais produtivos e eficientes. O uso racional dos recursos envolve, por consequência, o processo decisório, decisões são tomadas constantemente em toda a cadeia produtiva de qualquer indústria ou mercado, sendo fundamentais para a administração. Na indústria do petróleo, essa problemática apresentada não é diferente.

As empresas produtoras de petróleo tentam buscar o óleo onde quer que ele esteja, condicionado à viabilidade econômica de sua exploração e produção. No Brasil, foram descobertas, ao longo do tempo, grandes reservas de petróleo no mar, em especial na Bacia de Campos e, mais recentemente, nos campos do pré-sal (Figura 1.1). A distância em relação à costa brasileira, bem como a profundidade em que se encontram as reservas, faz com que exista um grande esforço logístico do ponto de vista da operação de suprimentos.

As atividades de exploração e produção de óleo e gás (E&P) no setor *offshore*, especificamente na camada pré-sal, têm imposto grandes desafios relacionados não apenas a tecnologias voltadas para engenharia de petróleo, mas, também, ligados às áreas de logística, gestão de operações e, infraestrutura, fundamentais para a continuidade operacional em E&P.

O mercado brasileiro de E&P possui várias particularidades. Embora a produção offshore representasse quase 30% do total mundial de produção de petróleo em 2016 (EIA, 2016), no Brasil este número atingiu 96% em 2018 (ANP, 2018a), particularmente na Bacia de Campos, uma área tradicional de produção do pós-sal e, mais recentemente, em campos do pré-sal, como a Bacia de Santos. Essas características consolidam uma desafiadora operação de exploração e produção de O&G em vários aspectos.

A logística de apoio *offshore* também chamada de logística de E&P, ou apenas logística *offshore* – cujo papel é transportar cargas e pessoas entre instalações

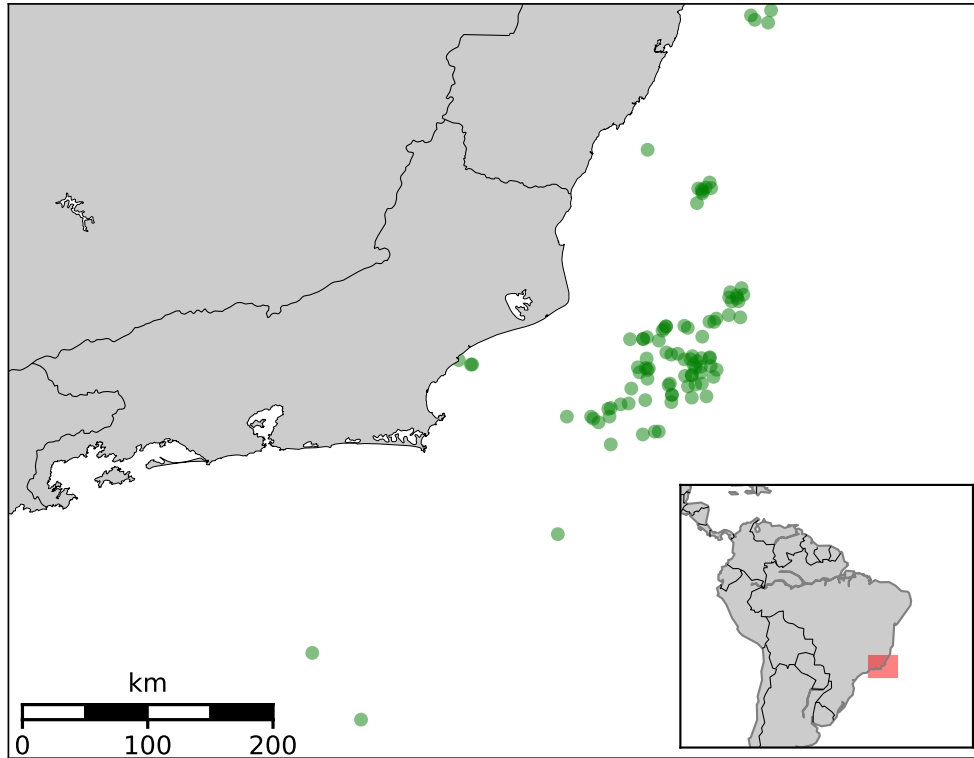


Figura 1.1: Unidades de produção e sondas em atividade *offshore* na Bacia de Campos e Santos no ano de 2016.

em terra, tais como bases de apoio e aeroportos, e unidades marítimas (UMs), a exemplo, sondas, plataformas e embarcações especiais – surge como uma área com margem relevante para o desenvolvimento de soluções baseadas em modelos para planejamento e operação de recursos e infraestrutura de forma mais eficiente. Na Figura 1.2 vê-se uma representação gráfica da rede logística descrita nesse trabalho.

Especificamente sobre as embarcações supridoras, o dimensionamento e a utilização adequados destas são fundamentais para manutenção de uma operação eficiente e com custo aceitável, dado que a quantidade de cargas movimentada é vultosa, tanto no sentido de entrega às unidades, como na remoção destas para tratamento em terra e reúso *offshore*. Comumente, o transporte marítimo é realizado por embarcações ou barcos chamados *Platform Supply Vessels* (PSVs). Já a troca de tripulações e o transporte de pessoal especializado são feitos geralmente via helicópteros.

O caso tratado nesta tese refere-se ao contexto logístico em 2016 da empresa Petróleo Brasileiro S. A. (PETROBRAS), a qual realizava suas operações de transporte de cargas a partir de quatro frotas de PSVs: (i) uma para transporte de cargas de convés e água, denominada, de agora em diante, de frota de carga geral (CG); (ii) outra para atendimento à demanda de diesel, denominada Oleiros; (iii) uma frota para transporte de fluidos e granéis sólidos necessários durante as atividades de




Figura 1.2: Rede logística *offshore*

construção de poços; e (iv) os Cimenteiros, empregados para a entrega de cimento utilizado em etapas específicas da construção de poços. Há ainda outras frotas com outros fins, tais como embarcações de prontidão contra eventos emergenciais, embarcações para manuseio de espias e barcos para reboque e manuseio de âncoras, chamados *Anchor Handling and Towing Supply* (AHTS).

É comum entre as quatro frotas para movimentação de cargas o uso do mesmo conceito de embarcação supridora disponível no mercado, o PSV, o qual, por projeto, é capaz de transportar simultaneamente mais de um tipo de carga. Isso significa que, por exemplo, quando um cimenteiro visita uma sonda, ele entrega cimento, mas não prevê uso de seu convés da embarcação para transportar carga geral, mesmo que a unidade marítima precise dessa carga no mesmo instante da entrega do cimento. O convés nesse caso não é intensivamente utilizado. Similarmente, um PSV de carga geral não prevê abastecimento de diesel a uma plataforma de produção durante a entrega de carga geral. Analogamente, as embarcações oleeiras não são programadas para entregar também carga geral às unidades marítimas.

Essa opção de operação preza a especialização, por tipo de carga, de um recurso originalmente projetado para ser multiproduto. Uma desvantagem clara disso é subutilização do recurso PSV. Por outro lado, é eminente a possibilidade de transporte de maiores quantidades de um mesmo produto por PSV.

Além do planejamento das entregas de carga, existe a necessidade de coordenar outras atividades que fazem parte da rotina das unidades, tais como o alívio de plataformas – remoção do petróleo produzido, que está armazenado em tanques – pouso de aeronaves que transportam pessoal e mergulhos de inspeção/manutenção. Esse cenário cria uma cadeia logística complexa, para a qual o planejamento operacional das embarcações supridoras torna-se uma tarefa crítica para a manutenção de um nível de serviço adequado no transporte de cargas entre bases de apoio e UMs,

bem como para redução de custos.

1.1 Relevância do tema

A indústria do petróleo caracteriza-se por grandes escalas de produção e exige a mobilização de uma grande quantidade de recursos, apresentando, com isso, um altíssimo nível de complexidade operacional relacionada aos seus vários processos.

O petróleo é o principal produto transportado no mundo em termos de tonela-gem, representando cerca de 4,8% do valor global de todos os produtos exportados. As remessas transportadas de petróleo bruto totalizaram US\$ 786,3 bilhões em 2015, sendo a maior parte exportada dos países do Golfo do México no valor de US\$ 325 bilhões, o que corresponde a 41,3% das exportações globais de petróleo bruto (SO-ROUSH e AL-YAKOOB, 2018). No golfo do México, de 2009 a 2010, havia 1500 unidades de produção de posição fixa em lâmina d'água inferior a 1000 pés e outras 47 unidades flutuantes (KAISER, 2016).

No ano de 2017 O consumo global de petróleo cresceu em média 1,8%, ou 1,7 milhão de barris por dia (*b/d*), acima da média de 10 anos de 1,2% pelo terceiro ano consecutivo. China (500.000 *b/d*) e os EUA (190.000 *b/d*) foram os que mais contribuíram para o crescimento registrado (BP, 2018).

De acordo com o IACHAN (2009), o uso de ferramentas quantitativas para apoiar o dimensionamento adequado da frota representa um ganho com um enorme potencial na contratação das embarcações. A exploração e a produção de petróleo no mar no Brasil são apoiadas por uma complexa rede logística. Até o momento, as taxas de contratação diárias permanecem relevantes, sendo em torno de US\$ 8.000 a US\$ 14.000 (DALEEL OIL & GAS SUPPLY CHAIN PORTAL, 2021).

Com a queda do preço do barril nos últimos anos, MENDES *et al.* (2017) alertam que a viabilidade econômica de alguns campos do pré-sal poderá ser questionada se os níveis de preço continuarem baixos por longo tempo ou se não houver uma redução dos custos de investimentos que os tornem esses campos atrativos em um cenário de preços baixos. Entende-se, portanto, que a necessidade da redução de custos talvez seja um dos principais indutores de avanços tecnológicos no setor de P&G.

Do ponto de vista da rede logística vinculada à exploração e produção offshore de petróleo, situado longe na costa, em altas profundidades e em local sem infraestrutura implantada, novos e desafiadores problemas apresentam-se: restrições mais apertadas, necessidade de tratar o problema em diferentes níveis hierárquicos, e em diferentes tempos de implantação, exigência de consideração de riscos e incertezas na abordagem dos problemas e na tomada de decisão. Sob a ótica ambiente científico, a solução destes problemas recai em generalizações desafiadoras de problemas bem conhecidos de pesquisa operacional, tais como: problemas de localização

hierárquicos de múltiplas camadas, com objetivo e restrições não lineares; problemas de roteamento de veículos, com múltiplos depósitos, janela de tempo e sincronização. Problemas de projeto de redes com restrições não lineares; e problemas de planejamento e seqüenciamento da produção. Todos estes configuram as preocupações mais recentes de pesquisadores de ponta no campo da Pesquisa Operacional.

Foi no contexto da situação descrita acima que se situou a presente tese. O resultado alcançado alia a contribuição científica com o desenvolvimento tecnológico ao implementar esta integração em um sistema que permite uma operação mais eficiente de indústrias do setor de petróleo e gás natural.

1.2 Objetivo

O presente trabalho procura resolver um problema de planejamento logístico denominado Problema de Alocação de Cargas Marítimas com Embarcações multiproduto. Para atingir esse objetivo geral, há três metas específicas. A primeira é apresentar, junto de uma definição formal do problema geral, como ele se insere na literatura científica de gestão de operações e logística de suprimentos. Essa etapa é concluída com a definição de um problema de pesquisa: É possível operar a logística de PSVs da exploração offshore da petrobras com menos embarcações?

A partir da definição de um problema de pesquisa, propomos como hipótese a utilização de um modelo matemático desenvolvido nesta tese. Como forma de validação desta hipótese, utilizamos de métodos de simulação para estimar o ganho de eficiência na operação com base em diferentes métricas de desempenho, como custo, emissões, nível de serviço entre outras.

Uma vez validada a hipótese da utilidade do modelo, exploraremos a utilização deste de forma generalizada com base em dois aspectos: i) construção de instâncias que sejam capazes de representar os dados que seriam encontrados numa situação real; e ii) estudar a eficiência dos métodos de resolução.

Como terceira meta para a pesquisa, realizamos um estudo de métodos heurísticos tendo a expectativa de que possam prover soluções de boa qualidade para o problema estudado. Serão avaliadas três implementações de metaheurísticas utilizando as instâncias produzidas artificialmente, cujos resultados são comparados com os do modelo matemático.

1.3 Estrutura do documento

Esta tese de doutorado está estruturada da seguinte maneira. No Capítulo 2 o problema é definido de maneira formal com a apresentação de uma revisão bibliográfica a respeito do tema e problemas correlatos.

No Capítulo 3 propomos um modelo de simulação capaz de representar, de forma fidedigna, aspectos essenciais da operação logística e testamos como diferentes políticas de gestão de frota e de alocação de cargas impactam na operação. Os resultados fornecem suporte para um estudo mais aprofundado do modelo para a decisão de escolha de embarcações e alocação de carga que é desenvolvido no capítulo seguinte.

Na sequência, o Capítulo 4 apresenta uma generalização do modelo de otimização apresentado no capítulo anterior. Para não nos limitarmos aos dados específicos da operação da Petrobras, neste mesmo capítulo é proposto um método de construção de instâncias artificiais que representem problemas realistas de diferentes tamanhos. A partir dessas instâncias, conduzimos uma série de experimentos computacionais com o modelo matemático proposto, os quais mostram a complexidade do problema de programação inteira mista e apontam como caminho de estudo a utilização de métodos heurísticos.

Na sequência, o Capítulo 5 apresenta uma abordagem heurística para resolução do problema de otimização. Diferentes heurísticas são comparadas tentando-se explorar com cada uma delas características especiais da estrutura do problema matemático. Uma grande análise de dados experimentais é conduzida para avaliar qual heurística apresenta melhor desempenho.

Por fim, o Capítulo 6 apresenta as conclusões gerais sobre a tese, incluindo um breve resumo dos resultados acadêmicos que foram obtidos ao longo da pesquisa e encerrando-se com a proposição de novas frentes de pesquisa que se abrem para trabalhos futuros referentes ao mesmo tema.

Capítulo 2

O Problema de Alocação de Cargas Marítimas com Embarcações Multiproduto

Neste capítulo, o problema estudado será apresentado de maneira formalizada, sendo avaliados a formulação matemática do modelo determinístico, os métodos de geração de instâncias que representam o problema estudado e uma série de experimentos computacionais de validação e análise do desempenho da formulação.

A indústria petrolífera enfrenta grandes desafios logísticos nas atividades de E&P relacionadas à construção e à manutenção de poços, particularmente em termos de logística destas operações. Tais desafios incluem a necessidade de planejar a utilização de recursos e infra-estruturas, bem como a de coordenar o sistema logístico e outras operações relacionadas com as unidades marítimas (UTM). Exemplos destas operações incluem a descarga de petróleo, chegadas e partidas de voos de helicóptero com tripulação e pessoal especializado, e mergulho de manutenção.

O projeto do sistema logístico pertence às decisões estratégicas de uma organização, isto é, aquelas com efeitos de longo prazo e que influenciam de forma marcante o desempenho e a imagem da companhia. Estas decisões envolvem a determinação do número e da localização de terminais, o tipo e a quantidade de equipamentos a serem utilizados, os tipos de linhas e capacidades a serem adicionadas, entre outras. As decisões tomadas no nível estratégico serão as premissas utilizadas para o projeto da rede de serviços, que é o plano de transporte para atender à demanda enquanto opera o sistema de maneira eficiente (nível tático); e para o planejamento operacional.

Vários campos podem ser pesquisados quando se lida com a logística *offshore*, tais como os problemas de coleta e entrega, roteamento e clusterização. Existem também algumas especificidades do problema já estudadas pela literatura, tais como

a condição de multidepósito (mais de um porto, no caso), a limitação dada por janelas de tempo e a existência de uma frota heterogênea. Há, portanto, bastante material na literatura, entretanto dificilmente existe algum material que aborde de forma unificada todos estes assuntos. Exemplos de como a operação ocorre em diferentes partes do mundo são citados em vários artigos e várias proposições são realizadas.

2.1 Descrevendo o problema

No problema estudado nesta tese, unidades de produção, sondas e outras unidades especiais em alto mar são clientes num sistema logístico de suprimento. Continuamente, essas unidades marítimas realizam pedidos de entrega para diferentes tipos de produtos, como carga de convés, óleo diesel, água, entre outros. Cada pedido é composto, portanto, de um tipo de produto e uma determinada quantidade. A Tabela 2.1 apresenta um exemplo de lista de pedidos.

O porto representa o depósito, ou seja, o local onde todas as mercadorias são coletadas e mantidas prontas para a entrega. Todo porto dispõe de um espaço físico limitado para o carregamento de navios chamado berço, os quais são lugares no porto onde as embarcações ficam ancoradas para o carregamento. Existem diferentes tipos de configurações para berços em portos, sendo as mais comuns a contínua, na qual mais de um barco pode ser alocado no mesmo berço, e a discreta, em que cada berço pode ser utilizado por um único navio. A decisão sobre como fazer a alocação de uma embarcação específica para um local físico em um porto para operações de manuseio realizadas durante um determinado período de tempo é conhecida na literatura como problema de alocação de berços ou *berth allocation problem*. Na operação que estudamos, a programação dos berços é um dado inicial conhecido e preparado previamente. Cada rota possui, portanto, um conjunto de janelas operacionais fixas nas quais as viagens podem ser carregadas.

A capacidade de estoque do depósito não será considerada, portanto é tratada como ilimitada. Por outro lado, verifica-se uma infraestrutura limitada para o carregamento de navios, bem como há outras limitações à operação portuária. Essas outras limitações incluem o número de berços nos quais os barcos podem ser ancorados para carregamento, o número de canais onde os navios podem trafegar e a produtividade dos guindastes e demais equipamentos de carregamento, o que faz com que cada janela tenha um prazo máximo para encerrar suas atividades. Essas restrições são resolvidas em uma etapa anterior de planejamento por meio da resolução do problema de alocação de berços e agendamento de tarefas. A tabela 2.2 apresenta um exemplo dos horários destas operações para um conjunto de rotas com duas viagens para cada rota.

A distribuição dos pedidos é feita com embarcações do tipo PSV (*platform supply vessels*). Sendo o dimensionamento de frota um problema relevante, deve-se levar em conta o fato de que na falta de navios não é possível a contratação de adicionais no mercado à vista. Diferentemente de outros países, no Brasil não dispomos de um grande mercado de contratação de navios à vista para atender entregas que superem a capacidade da frota disponível pontualmente. Sendo assim, uma frota de embarcações foi previamente contratada e está disponível para a operação.

A frota de navios disponível é heterogênea, de modo que cada embarcação dispõe de compartimentos para carga que foram dimensionados no seu projeto de construção. Os navios podem encontrar-se em três situações: ancorados na fila de espera no fundeio; em trânsito - momento que vai do início do carregamento no berço ao retorno do último cliente da rota para o fundeio; ou inoperantes devido a manutenção programada ou parada por falhas. A Tabela 2.3 exemplifica uma lista de embarcações disponíveis e seus atributos. Cada navio possui uma capacidade para cada categoria de produto e possui um tempo de chegada estimado ao fundeio (*Expected Time Arrival - ETA*), sendo esse tempo igual a 0 quando o navio já se encontra ancorado na fila.

Considerando os níveis de decisões estratégica, operacional e tática do gerenciamento da cadeia de fornecimento, diferentes políticas e *trade-offs* podem ser analisados para este problema. Com o objetivo de comparar alternativas de políticas, foi utilizado um simulador de eventos discretos, apresentado em DE BITTENCOURT *et al.* (2021); VIANNA (2019), para representar as operações *offshore*, ao mesmo tempo em que se considerava a estocasticidade associada ao problema.

Para atender os pedidos de entrega requisitados pelas unidades marítimas, diferentes políticas de gestão da frota podem ser implementadas. No passado, optou-se no Brasil pela utilização de uma política de frotas especialistas. Nesse caso, cada barco foi especializado num tipo de produto. Alguns PSVs realizam entregas de carga geral apenas; outros, de Diesel, enquanto há embarcações que levam granéis, e assim por diante.

Por um lado, essa abordagem especialista subutiliza cada embarcação. As embarcações especializadas em carga geral de convés, por exemplo, viajam com seus tanques e silos vazios, gerando um custo de oportunidade. Com o tempo, essa especialização afetou inclusive os projetos dos navios, uma vez que os estaleiros, atentos a esse modo de utilização, começaram a priorizar o escopo que seria dado ao navio para reduzir custos. Por outro lado, esse modo de gerir a frota foi pensado para atender necessidades estratégicas à época. Com o avanço da exploração em alto-mar e os elevados custos de manter as unidades com falta de algum material, optou-se por priorizar o nível de atendimento, pois distribuindo as cargas entre diferentes navios, era possível reduzir o risco de falta.

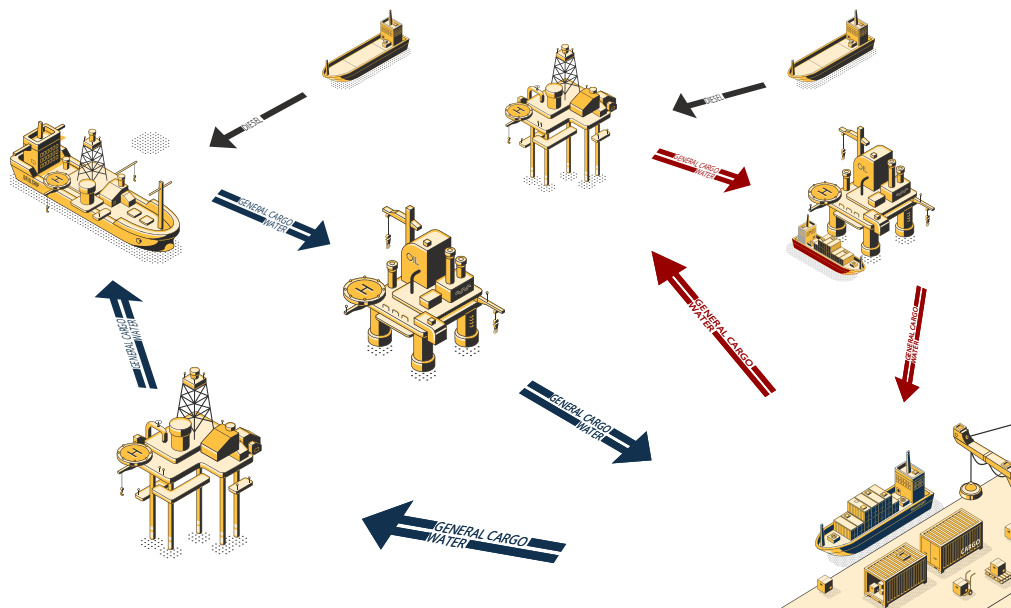


Figura 2.1: Representação da operação com frota especializada.

Como alternativa para esse paradigma, existe a opção de utilizar o que chamamos de frota multiproduto. Na frota multiproduto as embarcações podem utilizar todos os seus compartimentos para entregar diferentes produtos. Essa gestão da frota aumenta a taxa de utilização dos barcos e possivelmente pode gerar grandes reduções de custos. Seu ônus está no fato de concentrar os esforços para a mesma rota de clientes em um número reduzido de navios, podendo ocasionar mais faltas de estoque. As duas estratégias estão resumidas nas Figuras 2.1 e 2.2.

Na política de frota especialista, conforme ilustrado na Figura 2.1, a frota de navios é segmentada conforme a carga. Assim, uma frota é dedicada à carga de convés e à água (setas azuis e vermelhas), enquanto outra é usada para transportar diesel (setas pretas). Sendo altamente regulares e previsíveis, a carga de convés e as entregas de água podem seguir rotas pré-agendadas com poucos problemas em caso de atrasos. Entretanto, a escassez de diesel pode facilmente levar a paradas não programadas, gerando custos muito elevados. Portanto, veículos dedicados à entrega de diesel fazem entregas sob demanda, transportando óleo diesel dos navios-tanque maiores estrategicamente distribuídos por toda a bacia.

Como alternativa, propomos a política de frota agregada, como ilustrado na Figura 2.2. Esta estratégia permite o transporte simultâneo de diferentes produtos na mesma embarcação, resultando em redução de custos por meio da utilização dos compartimentos dos navios que, no modelo anterior, restariam ociosos. Enquanto a estratégia anterior focava a manutenção de um alto nível de serviço, o método aqui proposto prioriza o planejamento considerando o *trade-off* entre nível de serviço e custos.

Além das políticas de gerenciamento de frota acima mencionadas, o método

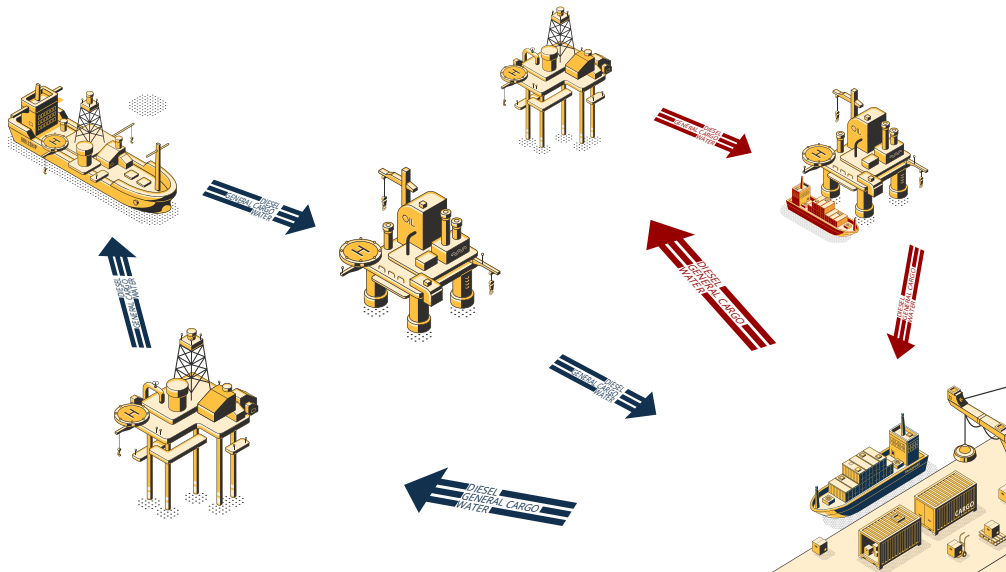


Figura 2.2: Representação da operação com frota multiproduto.

para a escolha de quais pedidos, dentre os que compõe a fila, serão embarcados e qual veículo fará o transporte é um segundo problema de interesse deste capítulo. Analisamos dois procedimentos diferentes: a regra FIFO (*first in first out*) e uma técnica baseada em programação matemática.

A regra FIFO é uma abordagem tradicional e comumente usada em problemas logísticos. Nesta estratégia, os pedidos são priorizados para entrega de acordo com sua antiguidade na fila de pedidos. Além disso, os barcos também são selecionados pela mesma regra. Portanto, a embarcação que aguarda há mais tempo no fundeio é escolhida para levar, na próxima viagem disponível para carregamento, o conjunto máximo de pedidos que respeite tanto o limite de tempo de berço, quanto a capacidade física da embarcação. Esta abordagem é a que vinha sendo utilizada pela empresa e será tratada como caso base de referência para a discussão de resultados.

Em oposição à regra FIFO, propomos um novo método de decisão, formulado como o seguinte problema matemático. Considerando (*i*) um conjunto de clientes organizados em rotas, (*ii*) um conjunto de pedidos feitos por cada cliente com prazos e, (*iii*) uma frota heterogênea de PSVs; estamos interessados em determinar (*a*) qual navio realizará cada viagem (*b*), quais pedidos serão transportados em cada viagem, (*c*) e a hora em que cada navio chegará aos locais (clientes e base de fornecimento). O objetivo é maximizar o nível de serviço (definido pelo percentual de pedidos entregues no prazo), evitando, simultaneamente, recusas de pedidos e rupturas de estoque. As principais restrições são as capacidades das embarcações e as janelas de tempo dos berços. Determinamos a solução ótima a fim de melhorar os níveis de serviço, permitindo assim a redução da frota em ambas as políticas da frota.

Pedido	Produto	Quantidade	Cliente	Rota	Prazo
1	Diesel	792	4	9	265
3	Diesel	238	14	5	319
4	Diesel	377	25	2	468
5	GC	1	1	8	144
6	GC	1	1	8	288
7	GC	1	1	8	288
8	GC	1	2	12	168
9	GC	1	2	12	168

Tabela 2.1: Lista de pedidos.

Rota	Sequência de Clientes	Tempo de berço	
		1ª viagem	2ª viagem
1	[49, 50, 56, 55, 57]	71	152
2	[27, 25, 60, 61, 62]	56	141
3	[22, 23, 35, 28]	19	105
4	[26, 21, 80, 29]	19	106
5	[15, 14, 47, 78, 18]	3	88
6	[54, 84, 51, 53, 52]	38	125
7	[17, 58, 79, 13, 48]	54	137
8	[30, 1, 31]	68	153
9	[4, 5, 44, 77, 46]	3	87
10	[39, 83, 42, 45, 41]	0	87

Tabela 2.2: Cronograma de viagens.

Barco	Capacidade			ETA
	CG	Diesel	Água	
1	88	1360	1850	0
2	85	1440	1450	293
3	85	1440	1450	384
4	95	1040	1350	264
5	85	1040	1400	384
6	85	1540	1600	0
7	56	740	1500	0
8	56	640	1350	320
9	56	640	1350	0
10	85	1480	1800	0

Tabela 2.3: Frota disponível.

2.2 Revisão bibliográfica

O estudo do planejamento de operações em logística de petróleo & gás, embora não seja um tema novo, é de extrema relevância e segue sendo prolífico em produção acadêmica. Nesta seção será apresentada uma revisão da literatura referente ao tema.

Diversos autores examinaram o planejamento logístico para operações de E&P. Entre estes estudos, um dos tópicos mais recorrentes é o problema de roteamento de veículos (VRP), no qual a alocação dos pedidos aos veículos e suas rotas são concomitantemente definidas. Como pretendemos mostrar, esse é um ponto no qual o problema estudado nesta tese é diferente dos demais, uma vez que pretendemos mostrar que uma boa operação pode ser obtida desconsiderando as decisões de roteamento em escala operacional e deixando-as para uma etapa anterior no âmbito estratégico.

2.2.1 Problemas de Planejamento de Logística Upstream

Alguns dos primeiros trabalhos relacionados com o planejamento de PSV encontram-se em FAGERHOLT (1999), FAGERHOLT e LINDSTAD (2000), CHRISTIANSEN e FAGERHOLT (2002) e AAS *et al.* (2007) e estão profundamente relacionados com o roteamento e programação de embarcações.

O artigo de FAGERHOLT e LINDSTAD (2000) foi o primeiro a abordar sistematicamente o problema na área de logística *offshore*. Neste trabalho, os autores exploraram alguns dos desafios relacionados ao suprimento a instalações marítimas, assim como avaliaram o impacto de operações noturnas de PSVs no custo total logístico. Os autores descreveram o sistema logístico implantado naquele ano pela Statoil no Mar do Norte, os tipos de carga, a forma como é realizada a programação de visitas e as estratégias qualitativas para lidar com incertezas. Em uma análise quantitativa, os autores também determinaram e implementaram políticas de roteamento e programação utilizando programação inteira, para um grupo previamente selecionado de seis cenários e um horizonte de tempo de uma semana. Para lidar com as incertezas, os autores consideram 150% da demanda média em seu modelo de otimização, além de avaliações qualitativas da robustez de sua abordagem.

AAS *et al.* (2007) mostraram que, mesmo em pequenos casos da vida real, a aplicação de técnicas de otimização poderia levar a grandes economias. Além disso, os autores salientaram que, até aquele momento, ainda pouco estudo tinha sido realizado sobre o assunto.

Num artigo posterior, AAS *et al.* (2009) reforçaram a afirmação sobre a importância de aumentar a variedade de aspectos relacionados com o problema estudado na literatura e criticaram o fato de, até então, a maioria das obras concentrarem-se apenas no roteamento de PSV.

KAISER (2010), usando a operação no Golfo do México como contexto desenvolveu um modelo com o objetivo de estimar a frota e a frequência dos serviços necessários para uma operação de exploração e produção. Este modelo, como apontado pelo autor, encontra limitações na grande complexidade da operação estudada ao tentar atacar diferentes estágios do E&P ao mesmo tempo.

HALVORSEN-WEARE e FAGERHOLT (2011) abordaram o problema de criação de horários robustos para o problema de planejamento da embarcação de abastecimento. Os autores mostraram como o impacto das incertezas geradas pelas condições climáticas alteram o desempenho do planejamento do navio e, para lidar com isso, acrescentaram parâmetros de robustez ao modelo previamente estudado em HALVORSEN-WEARE *et al.* (2012). Mais tarde, SHYSHOU *et al.* (2012) propôs uma heurística LNS para a mesma formulação.

Quanto ao cenário de produção de petróleo brasileiro, LEITE (2012) fez uma análise abrangente sobre logística *offshore*, tratando do estudo de caso da PETROBRAS. O trabalho tratou de recursos, principalmente barcos, facilidades em terra, composição típica/variabilidade da carga de deck e indicadores-chave de desempenho. Fez-se uma análise empírica, com o objetivo de reduzir o tamanho da frota e aumentar o nível de serviço no transporte de carga de deck, ao final, identificaram aspectos que poderiam gerar melhorias.

HALVORSEN-WEARE e FAGERHOLT (2016) voltaram ao problema de planejamento de embarcações de abastecimento com a introdução de uma nova formulação de fluxo em arco. Esta formulação foi inovadora porque, não seria mais necessário listar previamente todas as viagens viáveis. Por outro lado, este modelo provou ser menos eficiente em alcançar soluções comprovadamente ótimas. A seguir, BORTHEN *et al.* (2018) propuseram uma heurística baseada em busca genética para resolver problemas de planejamento de embarcações de suprimento de maior porte.

KISIALIOU *et al.* (2018a) introduziram uma novas características ao problema por permitir saídas flexíveis do porto e a possibilidade de acoplar pares de embarcações trocando seus cronogramas. Por partidas flexíveis, entende-se que há um conjunto discreto de opções de horário de partida disponíveis para o início das viagens. Embarcações acopladas são embarcações que trocam seus horários na segunda metade do horizonte de planejamento das embarcações. Esta estratégia permite a redução de custos, relaxando a restrição de não sobreposição de viagens.

As incertezas na demanda podem tornar o planejamento inadequado para transportar todos os suprimentos dos clientes, levando assim a custos extras devido a contratação de embarcações no mercado spot. Com isto em mente, KISIALIOU *et al.* (2019), ampliaram a análise introduzindo as incertezas na demanda das unidades como um elemento a ser considerado na preparação do planejamento e da programação da frota.

SEIMETZ CHAGAS *et al.* (2022) abordam de forma integrada o planejamento de atividades portuárias com o planejamento de rotas de entrega. Devido ao crescimento de complexidade que deixa o problema quase intratável, optou-se por uma abordagem de três fases. Na primeira as unidades são agrupadas com uma heurística de clusterização e esses clusters são dado de entrada de um problema de roteamento periódico. Com rotas periódicas definidas, as janelas de carregamento no porto podem ser planejadas, na segunda fase, em conjunto das demais atividades realizadas nos berços. Por fim, a terceira fase consiste em resequenciar as unidades de cada rota para reduzir tempos de espera e satisfazer janelas de tempo operacionais.

Alguns trabalhos analisaram os *trade-offs* existentes no problema de planejamento de embarcações de abastecimento. NORLUND e GRIBKOVSKAIA (2013) apresentaram uma nova dimensão ao introduzir a redução de emissões em operação por meio da otimização da velocidade da embarcação. Este conceito de agendamento robusto e emissões foi aprofundado em NORLUND *et al.* (2015) utilizando os mesmos métodos de otimização de velocidade, mas com a introdução de parâmetros de robustez para lidar com as incertezas decorrentes das condições climáticas. KISIALIOU *et al.* (2018b) propuseram uma metodologia para a geração de agendamentos robustos levando em conta o trade-off entre o nível de serviço e os custos da embarcação. Para lidar com situações nas quais o planejamento precisa ser alterado

BORTHEN *et al.* (2019) propuseram uma otimização bi-objetiva com o objetivo de minimizar custos enquanto tenta mudar o cronograma o mínimo possível.

2.2.2 Gestão de pedidos e planejamento de entregas

Na subseção anterior vimos como o trabalho anteriores cobriram o planejamento das operações de suprimento e a elaboração de rotas e cronogramas de entrega. Um aspecto essencial do problema abordado nesta tese, entretanto, diz respeito à gestão de pedidos e ao planejamento de suas entregas.

Este problema de gerenciamento de pedidos já foi trabalhado na literatura de logística *offshore* de forma indireta no contexto de problemas de roteamento sendo AAS *et al.* (2007) uma das primeiras obras a fazê-lo. GRIBKOVSKAIA *et al.* (2008) trabalharam em uma metaheurística de busca tabu para um problema similar de roteamento de veículos em que uma única embarcação deveria realizar coletas e entregas em várias plataformas *offshore*.

ALBJERK *et al.* (2016), alguns anos mais tarde, acrescentaram o gerenciamento de interrupções ao problema da entrega da coleta. Os autores propõem tanto uma formulação de fluxo em arco quanto uma formulação de fluxo em caminho para determinar um novo conjunto de viagens para os dias seguintes a uma interrupção na operação. RODRIGUES *et al.* (2016) abordaram o problema da coleta e entrega no contexto de operações *offshore* com uma heurística *relax-and-fix*.

CUESTA *et al.* (2017a) consideraram que, no cenário brasileiro, é comum que embarcações programadas regularmente não consigam atender a todas os pedidos disponíveis, podendo assim ser solicitada uma viagem complementar para transportar os pedidos excedentes. Os autores formularam problemas de roteamento de várias embarcações com coletas e entregas para planejar com antecedência o uso de embarcações de viagem complementar, observando que, se as decisões de roteamento forem desconsideradas, o problema torna-se um problema de seleção de pedidos.

Um problema de seleção de pedidos semelhante foi estudado anteriormente em ANDERSSON *et al.* (2015). Os autores mostraram, por meio de simulação, que a aplicação de um modelo de programação inteira mista permitiria ganhos sobre uma abordagem FIFO para entregas de pedidos. Em ambos os trabalhos de ANDERSSON *et al.* (2015) e de CUESTA *et al.* (2017a), contudo, não foi considerado que a alocação de embarcações também poderia ser incluída no modelo, aumentando a qualidade da solução. Expandindo DE BITTENCOURT *et al.* (2021) avançam na tese apresentada por ANDERSSON *et al.* (2015) e por meio de um simulador integrado com um modelo de otimização capaz de decidir tanto a alocação de pedidos, quanto a de embarcações, demonstram que é possível reduzir consideravelmente a quantidade de embarcações utilizadas na operação sem perda de nível de serviço.

Capítulo 3

Estimando o impacto de uma boa gestão integrada de pedidos e frota

Ao trabalhar com uma operação complexa e custosa como exploração e produção de petróleo, o potencial de novas ideias precisa, antes de tudo, ser validado experimentalmente de forma robusta para que se possa cogitar modificações na operação real. Parte da complexidade dessa operação deriva das incertezas ao longo do processo logístico: barcos eventualmente quebram, os tempos de viagem e a produtividade dos recursos oscilam, entre outras eventualidades.

Modelos de simulação que consigam representar adequadamente essas incertezas são poderosos ambientes de validação de estratégias e laboratórios de ensaio para mudanças táticas e operacionais. Como apresentado em capítulos anteriores, a operação de suprimentos de E&P no Brasil apoiava-se nos seguintes pilares: frota especializada, gestão FIFO das listas de pedidos e das embarcações.

Para propor uma mudança numa operação deste tamanho, é preciso testar hipóteses exaustivamente para comprovar se as políticas propostas serão efetivas em garantir o nível de serviço adequado e reduzir custos. Neste capítulo apresentaremos os resultados obtidos no artigo DE BITTENCOURT *et al.* (2021) por meio da ferramenta APOLO (Avaliador de Políticas de Logística de apoio *Offshore*).

O *framework*, denominado APOLO (DE BITTENCOURT *et al.*, 2021; VIANNA, 2019), é baseado em um modelo flexível de simulação de eventos discretos, o qual permite a análise de toda a logística da cadeia de abastecimento *offshore* e a previsão do impacto das melhorias propostas. Dentro da simulação, é avaliada a diferença entre as formas de alocar os pedidos e os barcos disponíveis. Para esta etapa, assim como em uma abordagem FIFO simples, propomos uma estratégia mais sofisticada na qual incorporamos um modelo de otimização dentro da simulação de forma a obter alocações mais efetivas.

Para facilitar o entendimento do leitor sobre o problema, começaremos a primeira seção deste capítulo fornecendo uma descrição do modelo de simulação, destacando

os aspectos mais importantes da sequência de operação e sua implementação dentro do *framework*.

3.1 Modelo de simulação de eventos discretos

Com relação à sequência lógica de operações na simulação, podemos dividir os PSVs em dois grupos. O primeiro grupo engloba os PSVs que simultaneamente entregam a carga de convés, diesel e água sob a política de frota multiproduto, incluindo ainda os PSVs tradicionais, que simultaneamente entregam a carga de convés e a água na política de frota especialista; nomeamos isto como operação do tipo A. O segundo grupo engloba os PSVs que entregam estritamente óleo; operação esta que nomeamos como operação do tipo B. Nas seções seguintes, apresentamos uma análise aprofundada de cada uma destas operações.

Todo esse processo logístico possui incertezas que representamos dentro de um conjunto de quatro famílias de variáveis aleatórias. São elas:

- Movimentação de produtos - fluxo de carga de diesel (porto, UMs e navios-tanque), fluxo de carga de água (porto e UMs) e taxas de movimentação de cargas de convés e carga de fluidos (porto e UMs);
- Demandas das UMs - demanda de carga de convés, consumo de diesel e água, produção de água;
- Administração da frota - velocidade de navegação, eventos de inoperância e duração destes tempos, tempo de docagem e tempo gasto para trocar a tripulação em oleiros; e
- Fatores externos - a necessidade da frota de esperar para operar nas UMs ou navios-tanque, devido a algumas condições meteorológicas ou eventos limitantes nas unidades (operação de mergulho, pouso de helicóptero, operação de navio-tanque shuttle, e outros). No processo de simulação isto será representado por tempos de espera.

3.1.1 Operação Tipo A (PSVs portuário)

Neste tipo de operação, denominamos os veículos como PSVs portuários. Em cada etapa de tempo do simulador, este verifica vários itens, como detalhado no fluxograma da Figura 3.1. Se todos os itens estiverem satisfeitos, o simulador requer uma estratégia de alocação apropriada para selecionar o veículo e as cargas que serão carregadas, de acordo com o planejamento de carga detalhado na subseção 3.2. Para

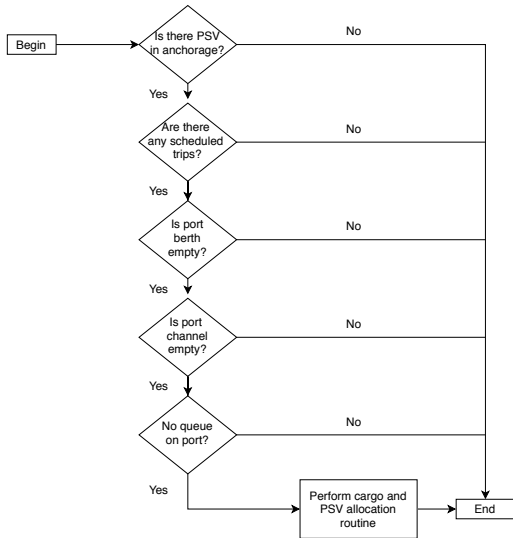


Figura 3.1: Alocação de carga.

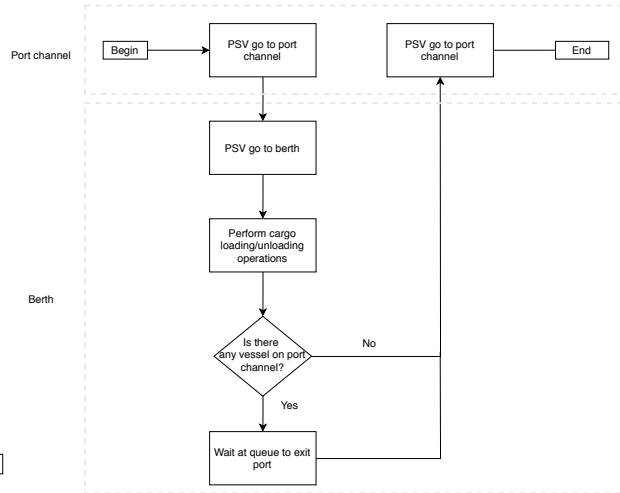


Figura 3.2: Operações no porto.

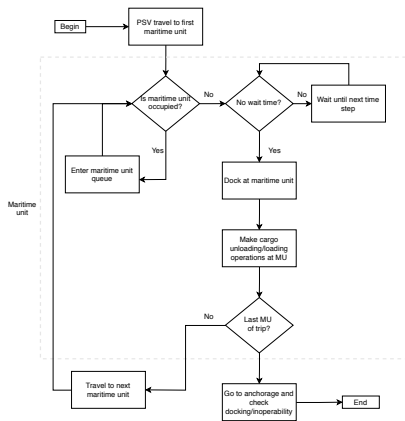


Figura 3.3: Operações de entrega de cargas.

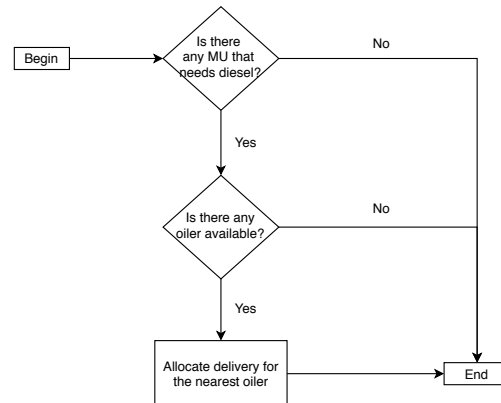


Figura 3.4: Alocação de cargas para oleiros.

realizar o carregamento, o PSV selecionado desloca-se do canal do porto para o cais e realiza atividades conforme detalhado na Figura 3.2.

Terminando o carregamento no berço, o PSV inicia sua rota para atender um conjunto de unidades marítimas, o que é descrito na Figura 3.3. Após retornar ao fundeio, o PSV pode experimentar eventos de inoperância, levando a uma impossibilidade de utilização temporária. Eventualmente, ele tem de retornar a uma doca seca para manutenção planejada. Durante todas as operações, os PSVs consomem diesel, cuja taxa de consumo depende de sua condição operacional e do local onde esteja.

3.1.2 Operação Tipo B (Oleiros)

Ao longo do tempo, as UMs consomem o diesel estocado em seus tanques, sendo o nível dos tanques de diesel de todas as UMs avaliado periodicamente. Se seu

estoque de diesel está abaixo de um determinado patamar, um pedido de entrega é produzido, conforme ilustrado na Figura 3.4. O pedido por entrega de diesel entra em uma fila para atendimento, que é ordenada do menor para o maior tempo estimado para a falta de estoque. A primeira UM na fila é ressuprida com o diesel necessário para completar seus tanques ou tudo o que estiver disponível no oleiro mais próximo, processo este que se repete até que não haja oleiros disponíveis ou até que a fila de UMs com pedidos de abastecimento esteja vazia.

Quando um oleiro chega à unidade, ele inicia uma sequência de operações como explicado na Figura 3.5. Cada vez que uma operação de carregamento é concluída, o oleiro verifica se seu próprio tanque precisa ser reabastecido; se necessário, o navio move-se para uma bóia para reabastecimento (Figura 3.5). Em seguida é verificado se chegou o momento de troca de tripulação no oleiro. Caso seja necessária, o navio viaja para o porto e inicia um procedimento semelhante ao carregamento do PSV portuário previamente explicado. Finalmente, se nenhuma outra operação for necessária, o oleiro torna-se disponível e espera por um novo pedido de diesel, sendo o consumo de diesel nesta operação semelhante ao da operação Tipo A.

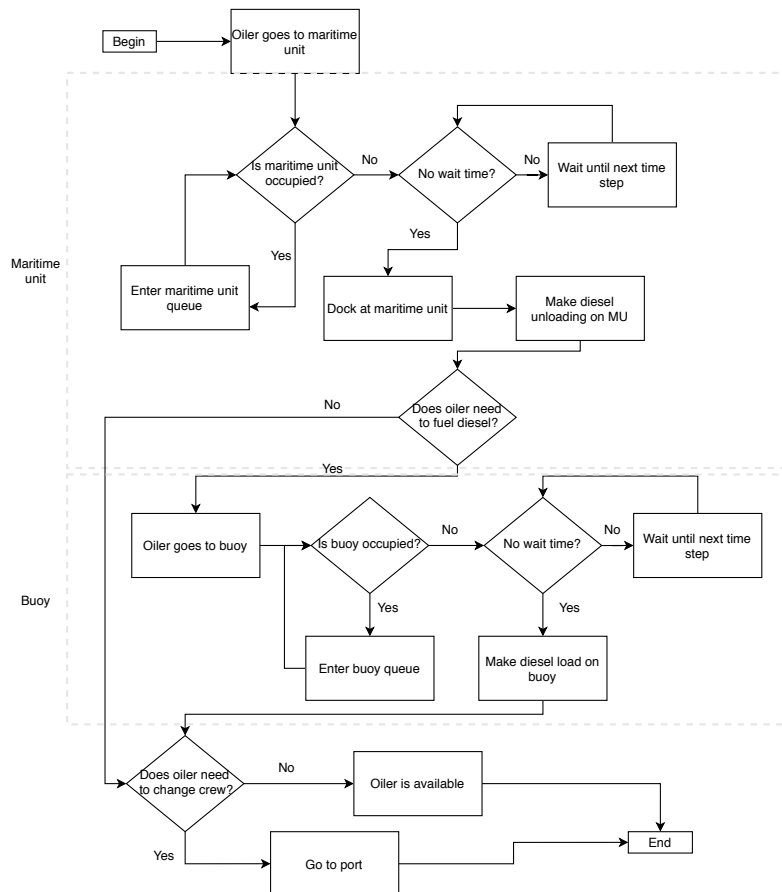


Figura 3.5: Operação de entrega do PSV oleiro.

3.1.3 Estruturas do modelo de simulação

Similar a um modelo de simulação de eventos discretos tradicional, nosso modelo de simulação é composto de entidades, locais e recursos. As entidades iniciam e respondem aos eventos de simulação, tendo sido consideradas as seguintes entidades:

- Viagens programadas: janelas de tempo operacionais quando as partidas para uma determinada rota são permitidas com frequência semanal; e
- Pedidos: mercadorias demandadas pelos clientes, incluindo água, diesel e carga de convés. Cada pedido tem atributos específicos, tais como o produto encomendado, quantidade e data de vencimento.

Os locais representam pontos fixos onde todos os tipos de operações são realizados, podendo ou não ter uma restrição de capacidade associada. As localizações no modelo são as seguintes:

- Fundeio: área de espera onde as embarcações chegam de uma viagem e de onde partem para o porto, modelada como um local de capacidade ilimitada. Além disso, durante cenários inoperantes e de doca seca, as embarcações permanecem nesta área;
- Canal do porto: a passagem estreita que liga a área de ancoragem ao porto e o porto à baía;
- Berços portuários: onde ocorrem as operações de carga/descarga de PSV e mudança de tripulação. Um berço só recebe um único navio de cada vez. A capacidade do porto é o número de ancoradouros ativos;
- Unidade Marítimas (UMs): instalações localizadas na baía, responsáveis pelas operações de E&P e encarregadas da geração de pedidos. Elas só podem ser atendidas por um PSV de cada vez; e
- Bóias: estas estão localizadas em toda a baía; os petroleiros podem amarrar nestas áreas para encher seus tanques de diesel.

Os recursos são os elementos que realizam as operações de simulação e têm capacidade limitada. Os recursos modelados são os seguintes:

- PSVs portuários: os navios responsáveis pelo fornecimento dos pedidos da UM, os quais se alternam entre os seguintes status durante a simulação: carga de carga e descarga, viagem, espera, não-funcionamento e doca seca. Eles podem visitar a área de ancoragem, o canal portuário, o porto e as UMs;

- Oleeiros: os navios responsáveis pelo fornecimento de diesel solicitados na política de frota desagregada. Eles se alternam entre os seguintes status durante a simulação: carga de carga e descarga, viagem, espera, troca de tripulação, não-funcionamento e doca seca. Eles podem visitar a área de ancoragem, canal portuário, porto, UMs, e bóias; e
- Navios-tanque: navios localizados ao lado das bóias, sendo os responsáveis pelo fornecimento de diesel para vários tipos de embarcações na bacia. Precisam viajar periodicamente para os terminais de diesel no porto para encher seus tanques, alternando-se entre os seguintes status durante a simulação: carga, descarga e viagem, podendo visitar as bóias e o porto.

3.2 Estratégias de alocação

A seleção do navio e a alocação da carga para cada rota são importantes áreas de decisão na logística *offshore*. Portanto, investigamos duas estratégias de alocação: (i) uma heurística gulosa conhecido como FIFO e (ii) um método proposto baseado em programação inteira.

3.2.1 Estratégia de alocação first in, first out (FIFO)

A regra FIFO de alocação é uma heurística gulosa que atribui o PSV que se encontra há mais tempo no fundeio para a próxima viagem a ser carregada. Com relação à escolha de quais pedidos serão entregues, nesta estratégia, a lista de pedidos é ordenada do menor para o maior prazo de entrega e assim o barco selecionado é preenchido com o máximo de pedidos desta pilha que caibam no seu deque.

Para os demais tipos de carga (diesel e água), não há um cronograma pré-definido para o carregamento nas unidades. Quando um PSV chega à UM, o estoque da unidade é verificado. Se o nível dos tanques estiver abaixo do ponto de ressuprimento, o PSV abastecerá a unidade até encher o tanque ou, se sua capacidade for abaixo disso, com todo seu o próprio estoque.

3.2.2 Modelagem matemática

Como alternativa a regra FIFO de alocação de barcos e pedidos, propomos a utilização de um modelo matemático de programação inteira.

Seja C o conjunto de unidades marítimas, ou clientes, dispersos no oceano. Cada um desses clientes produz pedidos de entrega $r \in \mathcal{R}$ por uma certa quantidade Q_r^p de produto $p \in \mathcal{P}$ com prazo de entrega DD_r .

Existe uma frequência de atendimento das rotas de clientes, sendo o conjunto das viagens de atendimento para cada rota é definido como T . A rota de clientes de uma viagem t é chamada $\kappa(t) \subset C$ e é composta por uma lista dos clientes que compõem a rota em sua ordem de atendimento. Se um barco é designado para uma viagem $t \in \mathcal{T}$, o barco deve estar disponível para iniciar o carregamento no momento em que se inicia a janela de tempo de carregamento no berço definido por B_t . Além disso, toda a operação de carregamento precisa estar encerrada no limite superior da janela de tempo definido por UB_t .

O porto e os clientes definem um conjunto de localidades pelas quais os barcos deslocam-se. Uma localidade $j \in C \cup \{porto\}$ é chamada sucessora de $i \in C \cup \{porto\}$ se $i \wedge j \in K$ e a passagem do barco por i precede j e o tempo de viagem de i para j é dado por $S_{i,j}$.

Seja \mathcal{V} o conjunto de barcos. Cada barco $v \in \mathcal{V}$ possui uma capacidade C_v^p para transportar um produto do tipo p . Além disso, a frota operacional está ou no fundeio aguardando ser requisitada para para um novo serviço, ou em trânsito transportando pedidos. Portanto, cada navio possui um tempo esperado de retorno ao fundeio (ETA) dado por ETA_v . Se estiver em transito, o ETA é positivo; se no fundeio, $ETA_v = 0$.

Com respeito ao tempo de carregamento, temos de considerar que cada localidade possui uma taxa de produtividade distinta. Classificamos, portanto, dois tipos parâmetros a esse respeito. No porto, o tempo necessário para movimentar um unidade do produto p será dado por HP^p . Já nos clientes, o tempo para transferir uma unidade do produto p do PSV para a unidade marítima, ou cliente, c é dado por HC_c^p . A tabela 3.1 resume as notações adotadas nos modelos.

Tabela 3.1: Notações utilizadas para conjuntos, parâmetros e variáveis do modelo matemático

Notação	
Conjuntos:	
$t \in \mathcal{T}$	Viagem t e o conjunto ordenado de viagens ativas \mathcal{T}
$v \in \mathcal{V}$	Barco v e o conjunto \mathcal{V} de PSVs
$p \in \mathcal{P}$	Produto p e o conjunto de produtos, \mathcal{P}
$c \in \mathcal{C}$	Cientes c e o conjunto de clientes, \mathcal{C}
$\kappa(t) \subset \mathcal{C}$	Seqüência de clientes c servidos na viagem t
$\rho(t) \subset \mathcal{R}$	Lista de pedidos r que podem ser entregues na viagem t
$\zeta(c) \subset \mathcal{R}$	Conjunto de pedidos feitos pelo cliente c
Parâmetros:	
Q_r^p	Quantidade de produto p que compõe o pedido r
C_v^p	Capacidade para o produto p no barco v

ETA_v	Tempo esperado de chegada do barco v
B_t	Tempo em que se inicia o carregamento para a viagem t
UB_t	Tempo máximo de carregamento no berço para viagem t
$S_{i,j}$	Tempo de viagem entre as localidades consecutivas i e j
DD_r	Prazo de entrega do pedido r
HC_c^p	Tempo para movimentar uma unidade de produto p no cliente c
HP^p	Tempo para movimentar uma unidade de produto p no porto
$\alpha(t)$	Primeiro cliente da rota na viagem t
$\eta(i)$	Sucessor do local i

Variáveis de Decisão:

$z_t^r \in \{0, 1\}$	1 se o pedido r é entregue na viagem t
$y_v^t \in \{0, 1\}$	1 se o barco v é alocado na viagem t
$l_r \in \{0, 1\}$	1 se o pedido r é entregue no prazo
$h_r \in \{0, 1\}$	1 se o pedido r é recusado
$x_{p,v}^t \in \mathbb{R}_+$	Quantidade de produto p carregado no barco v para a viagem t
$f_{p,v}^t \in \mathbb{R}_+$	Capacidade disponível no barco v para o produto p na viagem t
$tl_c^t \in \mathbb{R}_+$	Tempo em que o barco chega no cliente c na viagem t
$t_r \in \mathbb{R}_+$	Tempo em que o pedido r é entregue
$w_c^t \in \mathbb{R}_+$	Tempo de operação no cliente c na viagem t
$wp^t \in \mathbb{R}_+$	Tempo de carregamento no porto na viagem t

Como é possível não haver capacidade suficiente disponível para transportar todos os pedidos da fila, é plausível que alguns pedidos de entrega sejam recusados. Portanto, nosso objetivo é maximizar o nível de serviço definido pela porcentagem de solicitações que são entregues dentro do prazo. Para fins de cálculo, consideramos como atrasado um pedido entregue após sua data de vencimento ou um pedido recusado. Considerando isto, formulamos o problema como o modelo matemático a seguir:

$$\min \sum_r (h_r - \frac{l_r}{|\mathcal{R}|}) + \sum_{p,v,t} (\frac{\max(B_t) - B_t}{B_t \cdot \max(C_v^p) \cdot |\mathcal{V}|} \cdot f_{p,v}^t) \quad (3.1)$$

s.t.

$$\sum_v x_{p,v}^t \geq \sum_{r \in \rho(t)} Q_r^p \cdot z_t^r \quad \forall p \in \mathcal{P}, t \in \mathcal{T} \quad (3.2)$$

$$\sum_t z_t^r \leq 1 \quad \forall r \in \rho(t) \quad (3.3)$$

$$\sum_v y_v^t \leq 1 \quad \forall t \in \mathcal{T} \quad (3.4)$$

$$\sum_t y_v^t \leq 1 \quad \forall v \in \mathcal{V} \quad (3.5)$$

$$x_{p,v}^t + f_{p,v}^t = C_v^p \cdot y_v^t \quad \forall p \in \mathcal{P}, t \in \mathcal{T}, v \in \mathcal{V} \quad (3.6)$$

$$ETA_v \cdot y_v^t \leq B_t \quad \forall v \in \mathcal{V}, t \in \mathcal{T} \quad (3.7)$$

$$h_r + \sum_t z_r^t = 1 \quad \forall r \in \mathcal{R} \quad (3.8)$$

$$h_r + l_r \leq 1 \quad \forall r \in \mathcal{R} \quad (3.9)$$

$$M \cdot l_r + t_r \geq DD_r \quad \forall r \in \mathcal{R} \quad (3.10)$$

$$M \cdot (l_r - 1) + t_r \leq DD_r \quad \forall r \in \mathcal{R} \quad (3.11)$$

$$t_r \geq tl_c^t - M \cdot (1 - z_i^t) \quad \forall t \in \mathcal{T}, c \in \kappa(t), r \in \rho(t) \quad (3.12)$$

$$t_r \leq tl_c^t + M \cdot (1 - z_i^t) \quad \forall t \in \mathcal{T}, c \in \kappa(t), r \in \rho(t) \quad (3.13)$$

$$tl_{\eta(i)}^t \geq tl_i^t + w_i^t + S_{i,\eta(i)} \quad \forall t \in \mathcal{T}, i \in C \cup \{porto\} \quad (3.14)$$

$$tl_{\alpha(t)}^t \geq B_t + wp^t + S_{base,\alpha(t)} \quad \forall t \in \mathcal{T} \quad (3.15)$$

$$w_c^t \geq \sum_{p \in \mathcal{P}} \sum_{r \in \zeta(c)} (HC_c^p \cdot Q_r^p \cdot z_r^t) \quad \forall t \in \mathcal{T}, c \in \kappa(t) \quad (3.16)$$

$$wp^t \leq UB_t \quad \forall t \in \mathcal{T} \quad (3.17)$$

$$wp^t \geq HPP \cdot x_{p,v}^t \quad \forall p \in \mathcal{P}, t \in \mathcal{T}, v \in \mathcal{V} \quad (3.18)$$

A função objetivo, 3.1, está dividida em duas partes. A primeira diz respeito à medição de nível de serviço, enquanto a segunda procura priorizar uma maior utilização dos barcos que realizarão viagens mais próximas de se iniciar.

Na primeira parcela da função objetivo definida por $\sum_r (h_r - \frac{l_r}{|\mathcal{R}|})$ procuramos reduzir a quantidade de pedidos recusados, o que é dado pelo somatório da variável h_r . Além disso, queremos aumentar a quantidade de pedidos entregues no prazo ($l_r = 1$ se r foi entregue no prazo). De um ponto de vista de negócio, é muito pior um pedido ser recusado e não sabermos quando será entregue do que apenas chegar com algum atraso. Dessa forma, ponderamos a variável de entrega no prazo pelo total de pedidos da lista $|\mathcal{R}|$.

A segunda parte procura priorizar a utilização da capacidade dos navios alocados em viagens mais próximas de se iniciarem. Isto é importante porque, entre a decisão do otimizador e o efetivo carregamento nos portos das últimas viagens programadas, podem ser geradas solicitações adicionais, impondo a necessidade de uma nova otimização. Portanto, é importante maximizar a utilização das embarcações que estão mais próximas de iniciar viagem, a fim de obter maior reserva de capacidade para viagens ainda distantes. Sendo assim, quando mais tarde inicia-se a janela de carregamento da viagem t , ou seja quanto maior o valor de B_t , menor é o numerador $\max(B_t) - B_t$. Dessa forma, para valores mais altos de B_t , menor é o peso atribuído a valores maiores da folga de capacidade $f_{p,v}^t$. Mais adiante, veremos como uma das restrições garante que, se nenhum barco for alocado para a viagem, teremos $f_{p,v}^t = 0$, o que interfere na função objetivo. Por fim, para evitar problemas de escala entre as

duas parcelas, dividimos a segunda metade da função objetivo por $B_t \cdot \max(C_v^p) \cdot |\mathcal{V}|$ e obtemos valores menores do que 1.

A restrição, (3.2), assegura que a quantidade total de produto p embarcado não seja menor que a soma da quantidade relativa aos pedidos desse produto p atribuídos a essa viagem. A restrição em (3.3) impõe que um pedido r deve ser atribuído a no máximo uma viagem.

A restrição (3.4) impõe que a mesma embarcação não pode ser atribuída a mais de uma viagem, o que dentro dos objetivos deste modelo, não é uma premissa limitadora. Ainda que seja possível que a embarcação consiga terminar a rota em tempo suficiente para fazer uma nova entrega dentro de um horizonte de tempo curto, essa tomada de decisão só será possível dentro do contexto da simulação quando este barco estiver de fato disponível novamente. Na sequência, a restrição em (3.5) garante que não mais que uma embarcação seja designada para a mesma viagem.

A restrição em (3.6) impede que as embarcações sejam carregadas com produtos que excedam sua capacidade; isto é o resultado da adição da quantidade do produto carregado $(x_{p,v}^t)$ à folga de capacidade $(f_{p,v}^t)$. Note que, caso nenhum barco seja escolhido para realizar uma viagem t , a variável de decisão y_v^t valerá 0, obrigando as demais a também serem 0.

A restrição em (3.7), impõe que uma embarcação não pode ser escolhida para uma viagem cuja janela de carregamento começa antes do tempo esperado de chegada da embarcação, o *ETA*, ao fundeio.

O próximo bloco de restrições aborda o nível de serviço e a contagem de tempo. A restrição em (3.8) mede se um pedido r foi recusado – se r não for atribuído a nenhuma viagem, ou seja, $\sum_t z_r^t = 0$, h_r deve ser 1. Se um pedido for recusado, então também é considerado como atrasado, conforme expresso na restrição (3.9). As restrições em (3.10) e (3.11) determinam se o pedido é entregue no prazo, ou seja, se $t_r \leq DD_r$, então l_r deve ser 1. Para calcular o tempo em que um pedido é entregue, as restrições (3.12) e (3.13) impõem que o tempo de entrega seja o tempo em que a embarcação chega ao cliente.

O tempo de chegada da embarcação ao cliente é calculado usando as restrições em (3.14) e (3.15). Para auxiliar a modelagem do tempo de chegada numa localidade utilizamos a notação $\eta(i)$ para definir um sucessor de uma localidade i . Como as rotas são pré determinadas, sabemos de antemão qual é a sequência de locais por onde uma embarcação deve passar a fim de completar a rota. Desta forma, o tempo em que a embarcação chega a um local sucessor i na viagem t , definido como $tl_{\eta(i)}^t$, é pelo menos igual ao tempo em que chega a localidade anterior, i , da rota (tl_i^t) acrescido do tempo de operação em i dado por w_i e o tempo de viagem entre os dois pontos definido por $S_{i,\eta(i)}$.

Devemos ainda calcular o tempo em que a embarcação chega ao primeiro cliente da rota ($\alpha(t)$). Esse tempo é pelo menos igual ao tempo em que se inicia a operação de carregamento no porto (B_t) acrescido do próprio tempo de carregamento, dado por wp^t e do tempo de viagem do porto ao primeiro cliente da rota nesta viagem, $S_{i,\alpha(t)}$.

Em seguida, temos as restrições que dizem respeito aos tempos de carregamento nos clientes. Ao considerar que um tipo de produto é movido por vez (carregamento sequencial), a restrição (3.16) impõe que o tempo de trabalho em cada cliente seja maior ou igual à soma dos tempos de carregamento de todos os produtos. Se o um pedido r de quantidade de produto p definida por Q_r^p é entregue na viagem t , esse pedido possui um cliente $c \in \kappa(t)$ com capacidade de carregamento HC_c^p . O tempo gasto para movimentar esse pedido é dado por $HC_c^p \cdot Q_r^p$ sendo o total gasto para todos os produtos e todos os pedidos entregues em c nesta viagem t definido por $\sum_{p \in \mathcal{P}} \sum_{r \in \zeta(c)} (HC_c^p \cdot Q_r^p \cdot z_r^t)$.

Por fim, com relação ao porto, há dois tipos de restrições. A primeira restrição em (3.17) é um limite superior do tempo total passado no berço, ao paço que a segunda restrição (3.18) limita o tempo mínimo que durará a movimentação de cargas. Sabemos que existe um tempo máximo dentro do qual o barco deve ser carregado e então sair do berço e deixa-lo disponível para novas operações do porto. Desta forma, o tempo de carregamento no porto dado, por wp^t , deve ser, no máximo, o tempo limite de berço para a viagem t dado por UB_t . Além disso, consideramos que o carregamento no porto é mais produtivo que nas unidades e pode acontecer de forma paralela, ou seja, diferentes tipos de produtos podem ser carregados simultaneamente, resultando na restrição em (3.18), que define que o tempo de carregamento no porto será, no mínimo, igual ao do produto que consumir mais tempo para ser movimentado para carregar o navio.

3.3 Experimentos computacionais

Os experimentos computacionais consistiram em duas etapas. A primeira foi um estudo de validação do simulador para garantir que ele representasse adequadamente o sistema logístico estudado. Já a segunda foi composta de um estudo de caso em que foi comparada a diferença de desempenho de um caso base (como a operação vinha sendo desempenhada) com diferentes políticas de gestão da frota e dos pedidos.

O Avaliador de Políticas de Logística de apoio *Offshore* (APOLO) e as estratégias de alocação de carga – tanto a regra FIFO quanto o modelo matemático – foram implementados com a linguagem de programação *python*. Para lidar com o modelo de programação inteira, utilizamos a API de modelagem em *python* do *solver* comercial Gurobi 8.0, enquanto a validação do modelo foi feita através no *software*

de simulação Promodel 14.0. Todos os testes e resultados foram obtidos em um servidor com as seguintes configurações: Intel Xeon CPU E5-2620 v4 @ 2.10 GHz com dois processadores, 256 GB de memória RAM e sistema operacional Windows Server.

3.3.1 Validação do modelo proposto

O processo de validação é uma etapa importante na construção de um simulador de eventos discretos, pois pode garantir que a simulação represente com precisão a realidade. Em uma validação ideal, comparamos importantes indicadores de desempenho obtidos durante uma operação real com os resultados obtidos por meio de um simulador. Entretanto, é importante salientar que os valores reais nem sempre estão disponíveis. Uma alternativa, apresentada por SARGENT (2010), é a comparação com outros modelos: esta validação indireta é um método que pode ser usado quando faltam informações, de modo que os resultados obtidos possam ser comparados usando um simulador previamente validado com dados reais.

Devido à indisponibilidade de dados reais, realizamos uma validação indireta contra o simulador proposto por ANSELMO *et al.* (2017). Sua metodologia foi previamente validada com um conjunto grande de dados reais fornecidos pela Petrobras, para ajustar distribuições estatísticas e determinar seus parâmetros. Para este fim, os autores, em colaboração com especialistas em transporte marítimo, selecionaram um grupo de indicadores-chave e compararam os resultados destes com dados reais para determinar a capacidade do modelo de reproduzir realisticamente os dados. Eles usaram o *software* Stat::Fit durante o processo de ajuste e testes estatísticos de Kolmogorov–Smirnov, com um nível de significância de 5% para classificar e selecionar as distribuições sugeridas pelo *software*.

Utilizando as mesmas distribuições estatísticas do simulador de ANSELMO *et al.* (2017), para validar nosso modelo, selecionamos 11 indicadores-chave de desempenho (KPIs). Estes indicadores podem descrever aspectos operacionais importantes do problema e também foram utilizados para a validação do simulador de base. A tabela 3.2 lista estes KPIs.

Para a validação, implementamos os dois modelos que simulam 180 dias de operação, com 30 replicações e tempo de aquecimento de 90 dias. Consideramos ainda o cenário de política de frota desagregada, com o modelo de alocação FIFO. Os resultados obtidos pelos dois modelos e a discrepância entre eles são apresentados na tabela 3.3.

Seis dos onze indicadores apresentaram um erro menor do que 1%, enquanto nove deles ficaram abaixo de 2,5% e nenhum indicador variou mais do que 6% entre os modelos. Dessa forma, os resultados levam-nos a considerar que o modelo é válido

Categoria	Indicador	Frota	Descrição
Tempo	Tempo de Viagem	PSV transportando carga geral e água	Intervalo de tempo médio necessário para o procedimento de atracação da embarcação e movimentação para a área de espera
Tempo	Aguardando para operação na UM	PSV de carga geral e água; e oleeiro	Intervalo de tempo médio necessário para iniciar a operação da embarcação na unidade marítima. Este intervalo resulta da espera por condições de mar seguras ou algum outro problema da unidade que impeça a transferência de suprimentos.
Tempo	Inoperância	PSV de carga geral e água; e oleeiro	Intervalo de tempo médio de inoperância para o navio. Tipicamente devido à manutenção corretiva.
Tempo	Carregando na UM	PSV de carga geral e água; e oleeiro	Intervalo de tempo médio requerido para operações de carregamento na unidade marítima
Tempo	Carregando no porto	PSV de carga geral e água	Intervalo de tempo médio requerido para operações de carregamento no porto
Carga	Diesel por visita	Oiler	Volume médio de diesel entregue por visita a cada unidade marítima
Carga	Água por visita	PSV de carga geral e água	Volume médio de água entregue por visita a cada unidade marítima
Carga	Carga de convés por visita	PSV de carga geral e água	Volume médio de carga de convés transportada por navio

Tabela 3.2: Indicadores de desempenho (KPIs) selecionados para validação

Barco	Indicador	Simulador base	Simulador proposto	Erro (%)
PSV movimentando CG e água	Viagem (dias)	4.03	4.07	0.98
	Aguardando para operar na UM (dias)	0.46	0.46	0
	Downtime (dias)	2.43	2.29	5.76
	Descarregando na UM (h)	7.18	7.18	0
	Caregando no porto (h)	13.25	13.37	0.9
	Água por visita (m ³)	258.64	258.80	0.06
	CG por viagem	59.09	59.12	0.05
Oleeiro	Aguardando para operar na UM (dias)	0.49	0.50	2.04
	Inoperância (dias)	2.19	2.30	5.02
	Descarregando na UM (h)	10.74	10.54	1.86
	Diesel por visita (m ³)	632.28	618.78	2.13

Tabela 3.3: Resultados da validação

para analisar a operação, sendo capaz de reproduzi-la de forma verossímil.

Para ter certeza de que o número de replicações foi suficiente para colher estatísticas, foram feitos alguns testes adicionais com respeito ao nível de serviço das entregas de pedidos de carga geral, considerando os quatro casos a seguir: (i) política de frota especializada, com regra FIFO para alocação de pedidos e barcos; (ii) política de frota especializada, com uso do modelo de otimização para alocação de pedidos e barcos; (iii) política de frota multiproduto, com regra FIFO e; (iv) política de frota multiproduto, com modelo de otimização.

A Figura 3.6 apresenta os histogramas da distribuição do nível de serviço médio para cada estratégia com os valores de assimetria em destaque. Seguindo a regra geral de BULMER (1979), consideramos suficientemente simétricas as distribuições com assimetria de 0 a 0,5 e moderadamente assimétricas as que possuem valor de 0.5 a 1. Sendo assim, aplicamos o método de amostragem com *bootstrap* (WANG, 2001) para estimar adequadamente os intervalos de confiança para as distribuições de nível de serviço para as estratégias (ii) e (iii) por apresentarem assimetria moderada. Para as estratégias (i) e (iv) o valor da estatística t-student $t_{n-1,\alpha/2}$ para o nível de confiança requerido, a semi-amplitude (ou precisão) h será dada por $(t_{n-1,\alpha/2} \cdot \sigma) / \sqrt{n}$ e pode ser visto no resumo dos resultados da tabela 3.4.

Foram utilizados os mesmos dois critérios utilizados por ANSELMO *et al.* (2017) para atestar que a quantidade de replicações era suficiente e, validar o processo modelado. No primeiro, construímos um intervalos de confiança ao nível de 95%, com semi-amplitude do intervalo de confiança devendo ser menor do que 1% da média; enquanto, no segundo, com um nível de confiança de 99%, a semi-amplitude do intervalo de confiança deve ser menor do que 2%.

Estratégia	Média	Desvio amostral	Método	Nível de confiança	h	% da média
(i)	0.8359	0.0112	t-Student	95% 99%	0.0042 0.0056	0.5% 0.67%
(ii)	0.8912	0.0042	<i>Bootstrap</i>	95% 99%	0.0015 0.002	0.17% 0.22%
(iii)	0.813	0.0148	<i>Bootstrap</i>	95% 99%	0.0054 0.0071	0.66% 0.87%
(iv)	0.874	0.0045	t-Student	95% 99%	0.0017 0.0023	0.19% 0.26%

Tabela 3.4: Intervalos de confiança para 30 replicações.

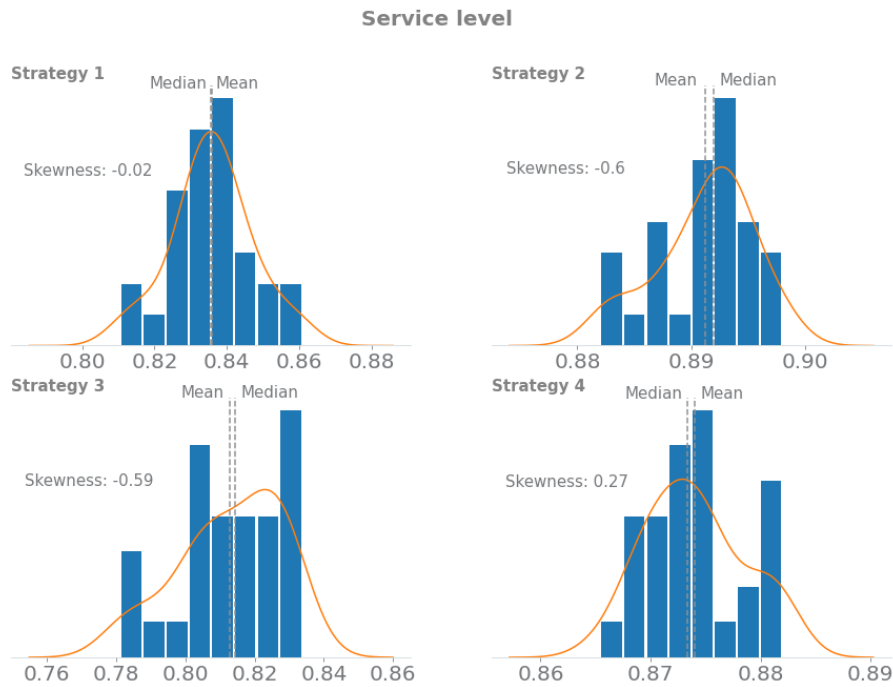


Figura 3.6: Histogramas de nível de serviço para os quatro casos simulados.

3.3.2 Estudo de caso

Utilizamos a metodologia proposta para simular um cenário de grande escala na costa sudeste brasileira, onde é produzida a maior parte do petróleo do país. Na Tabela 3.5, resumimos a configuração do caso, que consiste no suprimento de 90 unidades marítimas, divididas entre 23 rotas de atendimento. Essas unidades compreendem tanto operações na bacia do Espírito Santo quanto na de Campos, dispersas ao longo das costas do Espírito Santo e Rio de Janeiro, respectivamente. Cada unidade marítima tem demandas de entrega de carga de convés, água e diesel, além de pedidos de coleta de carga (*backload*). A frota atual consiste de 10 oleiros e 35 PSVs responsáveis pela entrega da carga de convés e água. O porto de Açu, que é utilizado para apoiar estas operações, dispõe de uma infraestrutura de seis berços de atracação dedicados a operações de suprimento *offshore*.

Todos os experimentos do estudo de caso foram realizados com um período de 90 dias de aquecimento e 180 dias de simulação válida, replicados 30 vezes, com os resultados obtidos tendo um intervalo de confiança de 95%.

Cenário *benchmark*

A política que vinha sendo utilizada nas operações *offshore* brasileiras considerava uma frota especializada e a regra FIFO para alocação de cargas, daqui em diante denominada Estratégia 1. No cenário *benchmark*, além destas características, a frota

Unidades de medida e escala		Principais parâmetros do cenário	
Consumo semana de diesel (m ³)	14222.3	UMs	90
Consumo semana de água (m ³)	12656.8	Rotas	23
Produção semanal de água (m ³)	6841.7	Bacia	Espírito Santo and Campos
Entrega semana de carga geral (unidade)	2740	Porto	Açu
Weekly pickup deck cargo demand (unidade)	2380	Berços no porto	6
Total distance travelled per trip (km)	422.84	Navios tanque	5
Total distance travelled per trip (km)	422.84	PSVs	35
Distance between port and MU (km)	177.49	PSVs oleiros	7

Tabela 3.5: Configuração do estudo de caso.

	<i>Benchmark</i>			Frota especialista e regra FIFO		
	Lower	Mean	Upper	Lower	Mean	Upper
Service level	83.33%	83.85%	84.63%	83.17%	83.59%	84%
Diesel stockouts	0	0.17	0.34	0	0.1	0.21
Water stockouts	0	0	0	0	0.03	0.1

Tabela 3.6: Principais indicadores de desempenho do cenário *benchmark* comparados com a Estratégia 1 com frota reduzida.

é composta por 10 oleiros e 35 PSVs entregando a carga de convés e água.

Na primeira etapa de nossa análise, usamos a metodologia proposta para determinar os indicadores de desempenho do cenário *benchmark*. Posteriormente, determinamos a redução da frota que pode ser alcançada utilizando a Estratégia 1, mantendo o mesmo nível de serviço de carga de convés do cenário *benchmark* procurando minimizar as ocorrências de desabastecimento de diesel e água.

Ao reduzir a frota de oleiros de 10 para 9 não são observados desabastecimentos adicionais de estocagem de diesel. Além disso, a redução dos PSVs que entregam a carga de convés e água de 35 para 33 barcos não piorou o nível de serviço (fração de pedidos de carga geral entregues no prazo) nem gerou ocorrências adicionais de falta de água. Esses resultados estão resumidos na Tabela 3.6.

Posteriormente, testamos as novas políticas aqui propostas: a política de frota multiproduto e a nova estratégia de alocação de carga baseada em programação matemática, as quais estão definidas na Tabela 3.7.

Estratégia	Política	Alocação	Composição de frota
1	Especialista	FIFO	33 PSVs de carga geral e água; 9 PSVs de diesel
2	Especialista	Otimização	33 PSVs de carga geral e água; 9 PSVs de diesel
3	multiproduto	FIFO	33 PSVs de carga geral, diesel, e água
4	multiproduto	Otimização	33 PSVs de carga geral, diesel, e água

Tabela 3.7: Estratégias avaliadas nos experimentos.

Operação	Indicador	Descrição
Carga Geral	Nível de Serviço	Percentual dos pedidos de carga geral entregue no prazo
Carga Geral	<i>Lead time</i>	Tempo médio gasto desde a abertura do pedido e sua entrega
Diesel	<i>Stockouts</i>	Ocorrência de falta de diesel na UM
Diesel	Espaço ocioso	Espaço ocioso no tanque de diesel do PSV após carregamento no porto (apenas na política multiproduto)
Água	<i>Stockouts</i>	Ocorrência de falta de água na UM
Gestão de frota	Consumo de combustível	Consumo total de combustível da frota (frota de oleiros e PSVs de CG/Água)

Tabela 3.8: Indicadores de desempenho avaliados.

Para a análise, consideramos os indicadores de desempenho listados na Tabela 3.8 que julgamos cobrir os principais aspectos da operação, dentre os quais, destacamos o nível de serviço de carga de convés e os estoques de diesel e água. O nível de serviço representa a capacidade de realizar as entregas dentro do prazo. As ocorrências de falta de estoque de diesel e água devem ter níveis próximos de zero para evitar o desligamento da unidade. Além destes dois indicadores, medimos ainda o *lead time* das entregas, o volume ocioso nos tanques de diesel e o volume de combustível consumido.

A tabela 3.9 resume os resultados da simulação para cada indicador.

O uso da otimização nas Estratégias 2 e 4 para resolver o problema de alocação resulta em uma consistente elevação no nível de serviço em comparação com os resultados obtidos usando a regra FIFO nas Estratégias 1 e 3. Simultaneamente, observamos uma redução significativa no *lead time* dos pedidos de carga geral, ocasionando um aumento na confiabilidade da operação.

As políticas de frota especializada alcançam melhores resultados em termos do nível de serviço em comparação com as políticas de frota multiproduto quando utilizando a mesma estratégia de alocação. O tempo economizado durante as operações de carregamento de diesel no porto e nas unidades marítimas reduz o tempo total de operação, conseqüentemente, os pedidos de carga geral são entregues em tempo mais curto, aumentando assim o nível de serviço.

Em todos os cenários, a média de ocorrências de desabastecimento de diesel e água foi baixa (menor do que uma ocorrência), com limite inferior do intervalo de confiança sempre em zero. Estes indicadores com valores próximos de zero garantem que a possibilidade de um ter seu funcionamento interrompido por uma falta de diesel ou água seja remota.

A ociosidade do tanque diesel é um parâmetro que só pode ser avaliado no caso da política de frota multiproduto, uma vez que na política de frota especialista apenas os oleiros responsabilizam-se por esse suprimento. Na Estratégia 4, usando

Indicador	Intervalo de confiança	Estratégia 1	Estratégia 2	Estratégia 3	Estratégia 4
Nível de Serviço Carga Geral	Inferior	83.17%	88.96%	80.74%	87.24%
	Média	83.59%	89.12%	81.30%	87.40%
	Superior	84.00%	89.28%	81.85%	87.57%
<i>Lead time</i> Carga Geral	Inferior	4.43	4.14	4.53	4.24
	Média	4.45	4.15	4.56	4.25
	Superior	4.47	4.16	4.60	4.26
<i>Stockouts</i> de diesel	Inferior	0.00	0.00	0.00	0.00
	Média	0.10	0.10	0.20	0.25
	Superior	0.21	0.21	0.43	0.51
Ociosidade em tanques de diesel	Inferior	—	—	253	717
	Média	—	—	256	720
	Superior	—	—	258	722
<i>Stockouts</i> de água	Inferior	0.00	0.00	0.00	0.00
	Média	0.03	0.3	0.00	0.33
	Superior	0.10	0.75	0.00	0.6
Consumo de combustível	Inferior	39026	39095	33101	33098
	Média	39255	39338	33197	33158
	Superior	39484	39581	33293	33218

Tabela 3.9: Resultados dos indicadores para todas as estratégias.

o otimizador, o volume ocioso do tanque é quase três vezes maior do que utilizando a regra FIFO na Estratégia 3, ganho este que sugere que a frota de PSV está viajando mais leve e com quantidades menores de diesel estocado. A redução da quantidade de diesel estocado nos PSV indica uma melhor gestão dos recursos de diesel no porto, com quantidades menores de diesel que não deixarão de ser entregues sendo transportadas durante cada viagem de PSV.

O consumo total de combustível de toda a frota não varia com a estratégia de alocação, dependendo apenas da política adotada para a frota. Devido a uma frota menor, as políticas baseadas em frota multiproduto atingem uma redução de $\sim 20\%$ no consumo de combustível em comparação com as políticas baseadas em frota especialista.

3.3.3 Perspectivas gerenciais

Em cenários reais, as conclusões de um tomador de decisão com base nas informações e dados disponíveis são altamente importantes. Seleccionamos três KPIs para auxiliar nas escolhas gerenciais:

Nível de serviço: definido como a porcentagem da carga entregue no prazo. O objetivo é atingir o nível mínimo aceitável definido em um acordo ou um nível que garanta a satisfação do cliente.




Figura 3.7: Total de emissões versus nível de serviço.

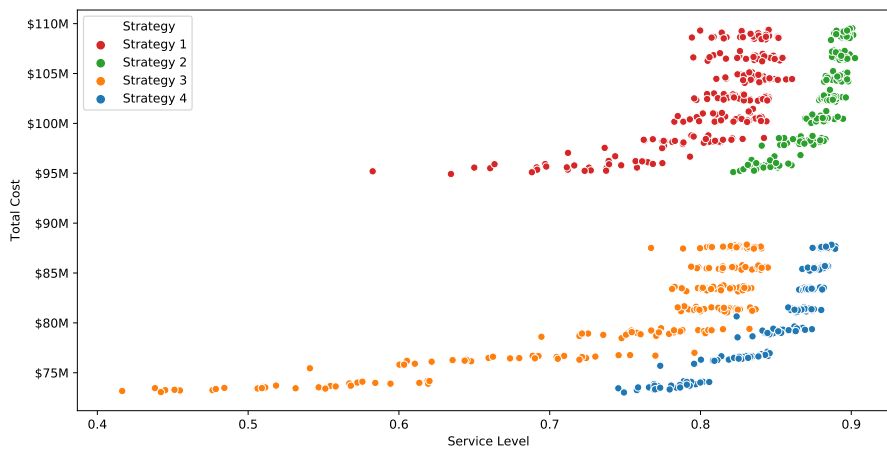


Figura 3.8: Custo total versus nível de serviço.

Emissões de gases de efeito estufa: Consideramos dois gases de efeito estufa primários para esta análise: o dióxido de carbono (CO_2) e dióxido de enxofre (SO_2). Usamos uma taxa de conversão de 3,17 para CO_2 e 1.184 para SO_2 , de uma tonelada de diesel para uma tonelada dos respectivos gases. O objetivo da muitas empresas é minimizar as emissões de gases de efeito estufa, pois este é um tópico sensível atualmente.

Custo operacional: É composto pelo custo da frota fretada e pelo custo do combustível consumido. O objetivo de uma empresa é reduzir o custo operacional. Consideramos uma taxa de afretamento de US\$ 11.000,00 por dia, que é a média dos custos encontrados em DALEEL OIL & GAS SUPPLY CHAIN PORTAL (2021). Para o custo do combustível, consideramos uma despesa de 2,06 USD por metro cúbico de diesel, com base na média dos preços diários em 2018, calculados usando dados de U.S. ENERGY INFORMATION ADMINISTRATION (2020).

Na Figura 3.7 vemos o *trade-off* entre nível de serviço e emissões: para se obter

um aumento de nível de serviço, exige-se um aumento ainda maior nas emissões de gases estufa. Quando são utilizadas as Estratégias 3 e 4, ambas com a política de frota multiproduto, há uma redução substancial nas emissões. Ainda na mesma figura, fica evidente que a utilização do modelo de otimização possibilita um aumento considerável no nível de serviço com o mesmo patamar de emissões do método FIFO.

Também analisamos a relação do custo como função do nível de serviço. 3.8. Um aumento no nível de serviço leva a um aumento nos custos operacional e de frota e no consumo de combustível. A utilização da política de frota multiproduto proporciona um ganho significativo em nível de serviço sem sacrifício financeiro. Além disso, o uso do otimizador pode levar a melhores níveis de serviço, mantendo o mesmo custo que o FIFO. A Estratégia 4, por sua vez, do ponto de vista do custo e do nível de serviço, mostra-se preferível às demais.

A figura 3.9 ilustra a variação do nível de serviço com as mudanças no tamanho da frota. Como mencionado anteriormente, frotas menores tendem a níveis de serviço mais baixos. Porém, evidencia-se uma vez mais que a utilização de modelos mais sofisticados de otimização possibilita o alcance de um maior desempenho da mesma frota em relação a uma regra FIFO, bem como a utilização de frota multiproduto permite redução significativa da frota por dispensar o uso de oleiros.

Com o auxílio de especialistas da operação, estipulamos, para fins de comparação, um nível de serviço mínimo aceitável de 80%. Com esse valor como meta, determinamos a frota mínima capaz de atendê-la. Definiu-se que a meta é atendida se o limite inferior do intervalo de confiança, dado nível de significância de 95%, ficar acima dela. Os resultados do dimensionamento da frota para cada estratégia estão listados na tabela 3.10 juntamente com os indicadores de desempenho e seus intervalos de confiança, resumindo os resultados observados até o momento. A Estratégia 4 opera no mesmo nível de serviço, utilizando a menor frota total (apenas 30 embarcações), com consumo de combustível de 5% a 20% menor e, conseqüentemente, menores emissões.

Estes resultados informam ao tomador de decisão que a Estratégia 4 é superior às outras e que os esforços relativos à sua implementação são recompensados com reduções de custo, queda de emissões e elevação do nível de serviço. É necessário observar que, há aspectos adicionais que não foram considerados nesse estudo mas são relevantes. Questões contratuais relacionadas à frota em disponibilidade e as mudanças de planejamento que se propagam para outros participantes do processo podem gerar restrições à implantação de uma nova estratégia de operação, porém extrapolam o escopo do presente estudo.




Figura 3.9: Tamanho de frota vs nível de serviço.

		Estratégia 1	Estratégia 2	Estratégia 3	Estratégia 4
Nível de serviço	Inferior	81.12%	83.91%	80.54%	81.84%
	Média	81.78%	84.31%	81.08%	82.48%
	Superior	82.45%	84.70%	81.62%	83.13%
Frota	Cost	\$79,200,000	\$75,240,000	\$63,360,000	\$59,400,000
	PSV	31	29	32	30
	Oiler	9	9	0	0
	Total	40	38	32	30
Custo de combustível	Inferior	\$21,206,283	\$20,403,650	\$17,952,315	\$16,989,270
	Média	\$21,341,696	\$20,548,157	\$18,006,926	\$17,106,036
	Superior	\$21,477,109	\$20,692,664	\$18,061,538	\$17,222,802
Emissões totais	Inferior	143,939	138,491	121,852	115,316
	Média	144,858	139,472	122,223	116,108
	Superior	145,777	140,453	122,594	116,901

Tabela 3.10: Resultados obtidos com frota mínima para atingir nível de serviço de 80%.

Indicator	Disaggregated policy		Aggregated policy	
Optimized fleet size	33	30	33	30
Optimization time (s)	0.04	0.01	0.03	0.01
GAP (%)	0	0	0	0
Constraints	1915	953	1512	950
Variables	2904	1087	2028	1003
Simulation time (s)	193	101	156	105

Tabela 3.11: Resultados obtidos pelo modelo matemático.

3.3.4 Visão geral do desempenho computacional da metodologia

Para avaliar o desempenho e a viabilidade da metodologia de otimização da alocação de carga e sua interação com o simulador de eventos discretos, selecionamos cinco indicadores para fornecer uma visão geral do seu desempenho computacional.

O gap de otimalidade, que é a diferença entre os limites superiores e inferiores atuais divididos pelos limites melhores e expressos em porcentagem, e o tempo de otimização foram usados para avaliar o desempenho da otimização. O número de restrições e o número de variáveis forneceram uma estimativa do tamanho do problema. O tempo de simulação reflete a interação com o simulador de eventos discretos, sendo a soma do tempo de simulação e do tempo para todos os processos de otimização. A tabela 3.11 lista os resultados do indicador de otimização para frotas com 33 e 30 PSVs operando no porto com Estratégias 2 e 4.

Uma análise da tabela 3.11 indica a eficiência do otimizador. Embora o problema tenha inúmeras restrições e variáveis, ele geralmente alcança solução ótima dentro de um tempo computacional baixo, assegurando uma aplicação viável nas práticas industriais reais.

É necessário observar os tempos computacionais porque a otimização é realizada repetidas vezes (48 chamadas do otimizador por semana de simulação). Nas figuras 3.10 e 3.11, apresentamos os tempos computacionais alcançados utilizando nossa metodologia. Mesmo no pior cenário, o tempo médio de uma replicação é inferior a 300 segundos nas estratégias que utilizam o otimizador para alocação. Por outro lado, conseguimos um tempo menor que 12 segundos para estratégias utilizando a regra FIFO na escolha das alocações.

3.4 Conclusões

Neste capítulo, apresentamos uma metodologia integrando otimização com simulação, a fim de representar as operações logísticas a montante no Brasil. Usando esta metodologia, foi possível replicar as operações atuais, combinando uma política de

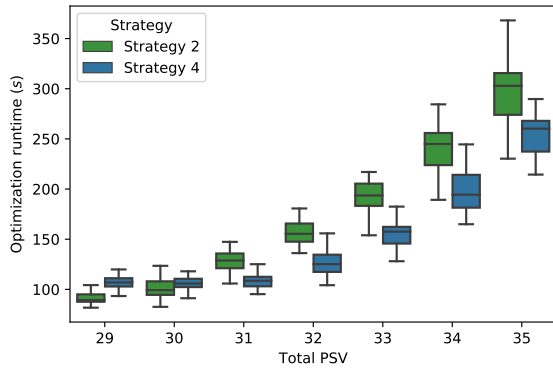


Figura 3.10: Tempo computacional da otimização.

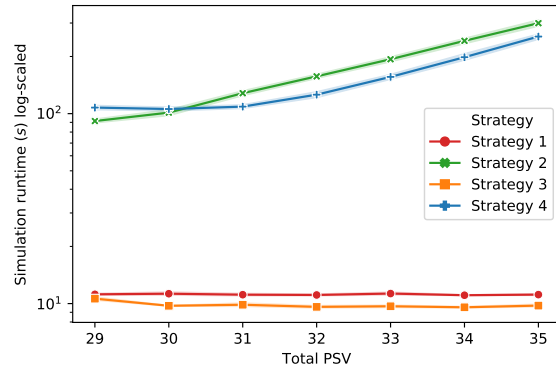


Figura 3.11: Tempo computacional da simulação.

frota especializada e a estratégia FIFO para a alocação de pedidos. Além disso, propusemos novos cenários considerando a política de frota multiproduto e o uso do modelo de otimização para a seleção de embarcações e para a alocação de carga no porto.

Usando esta ferramenta, poderíamos avaliar os impactos das novas políticas sobre importantes indicadores de custos operacionais: nível de serviço e emissões de efeito estufa. Particularmente, a estrutura proposta fornece importantes destaques quanto aos efeitos de cada política sobre o trade-off entre o dimensionamento da frota e os KPIs; espera-se que esta informação permita aos tomadores de decisão escolher a melhor alternativa com base nos objetivos das empresas em diferentes áreas.

Como conclusão geral para a seleção de políticas, pode-se afirmar que o transporte de múltiplos tipos de carga no mesmo navio de abastecimento é viável, pois permite reduzir significativamente os custos operacionais e as emissões de gases de efeito estufa, mantendo um alto nível de serviço de entrega de carga. Além disso, a alocação acoplada - abordagem de otimização - garante ganhos no nível de serviço para frotas de mesmo tamanho. Embora empregar a otimização como um processo interno do sistema de simulação tenha aumentado o tempo de execução de alguns segundos para alguns minutos, o ganho na qualidade da solução foi significativo.

Portanto, pudemos alcançar os objetivos previamente declarados neste estudo. Construímos uma estrutura integrando simulação com otimização para auxiliar os procedimentos de tomada de decisão na logística de PSVs, estrutura esta que nos ajudou a compreender o cenário da logística brasileira de petróleo e gás, que não foi estudado extensivamente. Desenvolvemos ainda um modelo de otimização para alocação de carga e seleção de veículos no porto, o qual foi embutido na estrutura de simulação, entretanto, este modelo também pode ser usado sozinho para operações diárias. Finalmente, acreditamos que as discussões aqui apresentadas contribuem para o esclarecimento dos aspectos gerenciais do problema.

O tema abordado neste estudo é amplo e desafiador e, como apresentado, possui

grande potencial para novas pesquisas e impacto prático na gestão de operações. Com isso em mente, no próximo capítulo iremos aprofundar ainda mais esse problema. Como ficou demonstrado, o modelo de otimização foi de extrema relevância para demonstrar o quão grande pode ser a redução de frota sem que seja preciso sacrificar o nível de serviço. Esse modelo porém, por estar embarcado num simulador, lida com uma escala de tempo diferente na tomada de decisão. Na sua vivência prática, o tomador de decisão quer planejar essas operações com alguma antecipação, para que não apenas as unidades tenham previsibilidade de suas entregas, mas também os operadores e a tripulação dos navios a tenham.

Assim sendo, no próximo capítulo iremos explorar maneiras de incorporar novas decisões ao modelo matemático, de forma que ele seja útil ao planejamento tático. Serão elas: reutilizar a embarcação para viagens futuras e lidar com mais produtos. Essas duas modificações sozinhas irão aumentar consideravelmente a complexidade do problema e seu custo computacional, exigindo novos métodos para resolvê-lo.

Capítulo 4

Um modelo tático de planejamento com múltiplas viagens

No capítulo anterior, construímos uma estrutura integrando simulação com otimização para auxiliar os procedimentos de tomada de decisão na logística de PSVs. O modelo de otimização proposto para a escolha de embarcações e da alocação de cargas foi o elemento central das estratégias que apresentaram melhores resultados nos indicadores de desempenho.

Este modelo, como apontado nas conclusões do capítulo 3, pode ser expandido para um escopo maior do que o de automatização de um processo de simulação. As decisões incorporadas no modelo de simulação são, na prática, revisitadas periodicamente por um analista/decisor humano e incorporadas ao planejamento logístico da operação. Assim, iremos ampliar o modelo de forma a torna-lo mais genérico e capaz de servir como apoio para a tomada de decisão dentro de um horizonte de planejamento em que embarcações são designadas para múltiplas viagens ao longo do tempo e passam a ter um cronograma de entregas pré-estabelecido.

4.1 Formulação matemática com múltiplas viagens e geração de instâncias

Nesta seção, iremos apresentar uma generalização do problema de planejamento de embarcações multiproduto com seleção de pedidos e janelas de tempo. Na sequência do modelo matemático, apresentamos os métodos de geração de instâncias que servirão de base para os próximos experimentos deste capítulo.

4.1.1 Definições

Seja \mathcal{C} o conjunto de unidades marítimas a serem atendidas, ou clientes, espalhados no oceano. Cada um desses clientes produz, ao longo do tempo, pedidos de entrega $r \in \mathcal{R}$ cada um com atributos do tipo volume Q_r^p de produto $p \in \mathcal{P}$ e um respectivo prazo de entrega DD_r .

Uma rota $g \in \mathcal{G}$ é definida como um conjunto de clientes ordenado pela sequência com que serão atendidos durante um ciclo de entregas. Cada rota, por sua vez, é atendida uma certa quantidade de vezes ao longo do horizonte de tempo do planejamento. Cada serviço de atendimento único de uma rota é chamado de viagem $t \in \mathcal{T}$, sendo $\kappa(t) \subset \mathcal{C}$ a sequência de clientes daquela viagem. Uma localidade $j \in \mathcal{C} \cup \{depot\}$ é chamada sucessor de $i \in \mathcal{C} \cup \{depot\}$ se $i \wedge j \in \mathcal{G}$ e o serviço de atendimento de i precede j , sendo o tempo de viagem de i para j dado por $S_{i,j}$.

Seja \mathcal{V} o conjunto de embarcações. Cada barco $v \in \mathcal{V}$ possui a capacidade C_v^p de transportar o produto p . Além disso, a frota pode encontrar-se ancorada no fundeio enquanto aguarda liberação para atracar no porto e iniciar um novo serviço, ou em trânsito. Sendo assim, cada barco possui um tempo esperado de chegada ao fundeio dado por ETA_v . Quando o barco já se encontra no fundeio aguardando para entrar no porto, seu $ETA_v = 0$; caso contrário $ETA_v > 0$. Como recurso de modelagem, considere o barco artificial $\bar{v} \in \bar{\mathcal{V}}$, que possui os mesmos atributos que v . O barco \bar{v} , na prática, é uma cópia do original v e representa a possibilidade de utilizar a embarcação uma segunda vez para outra viagem.

Com relação aos tempos de carregamento, o tempo gasto para movimentar uma unidade de produto p será definida como: HP_p se a movimentação ocorre no porto e HC_p^c se a movimentação ocorre no cliente c . Essas taxas são diferentes pois a produtividade dos guindastes para carregamento no porto são melhores do que em unidades marítimas.

A solução ideal para o problema consiste em entregar todos os pedidos dentro do prazo. Evidentemente, por não haver capacidade de transporte ilimitada, nem prazo infinito, é preciso aceitar que alguns pedidos sequer possam ser entregues, ou ser levados ao cliente dentro do prazo. Desta forma, a função objetivo é definida como a minimização do custo total definido pela soma dos custos de não entregar os pedidos com a soma dos custos de entregar com atraso.

A tabela 4.1 resume a notação utilizada no modelo.

4.1.2 Formulação matemática

Tabela 4.1: Notação utilizada para conjuntos, parâmetros e variáveis de decisão

Notação

Conjuntos:

$t \in \mathcal{T}$	Viagem t e conjunto de viagens \mathcal{T}
$v \in \mathcal{V}$	Barco v e conjunto de barcos \mathcal{V}
$\bar{v} \in \bar{\mathcal{V}}$	Barco clone \bar{v} e conjunto de barcos disponíveis para realizar uma segunda viagem
$c \in \mathcal{C}$	Cliente c e conjunto de clientes \mathcal{C}
$k \in \mathcal{K} k \subset \mathcal{C}$	Rota k e conjunto de rotas \mathcal{K} tal que k ;e um subconjunto de clientes \mathcal{C} que compõem
$p \in \mathcal{P}$	Produto p e conjunto de products \mathcal{P}
$r \in \mathcal{R}$	Pedido r e conjunto de pedidos \mathcal{R}
$\kappa(t) \subset \mathcal{C}$	Conjunto ordenado de clientes c atendidos na viagem t
$\rho(t) \subset \mathcal{R}$	Conjunto de pedidos r que podem ser entregues na viagem t
$\zeta(r) \subset \mathcal{T}$	Conjunto de viagens dentre as quais o pedido r pode ser entregue
$\delta(r) \in \mathcal{C}$	Cliente que fez o pedido r

Parâmetros:

Q_r^p	Quantidade de produto p demandada no pedido r
C_v^p	Capacidade do barco v para o produto p
ETA_v	Tempo estimado de chegada do barco v ao fundeio
B_t	Tempo em que se abre a janela para carregamento no porto para a viagem t
UB_t	Duração máxima das operações em berço na viagem t
$S_{i,j}$	Tempo de viagem entre duas localidades consecutivas i e j
DD_r	Prazo de entrega do pedido r
HC_p^c	Tempo de carregamento de um unidade de produto p no cliente c
HP_p	Tempo de carregamento de um unidade de produto p no porto
$\alpha(t)$	Primeiro cliente da viagem t
$\omega(t)$	Último cliente da viagem t
$\eta(i)$	Sucessor da localidade i
$\beta(r)$	Custo de recusar o pedido r
$\theta(r)$	Custo de entregar o pedido r atrasado

Variáveis de Decisão:

$z_r^t \in \{0, 1\}$	1 se o pedido r é entregue na viagem t
$y_v^t \in \{0, 1\}$	1 se o barco v é designado à viagem t
$l_r \in \{0, 1\}$	1 se o pedido r é entregue on time
$h_r \in \{0, 1\}$	1 se o pedido r is refused
$x_{p,v}^t \in \mathbb{R}_+$	Quantidade de produto p carregado no barco v para a viagem t
$tl_c^t \in \mathbb{R}_+$	Tempo de chegada do barco no cliente c na viagem t
$t_r \in \mathbb{R}_+$	Tempo em que o pedido r é entregue
$w_c^t \in \mathbb{R}_+$	Tempo de carregamento no cliente c na viagem t
$wp^t \in \mathbb{R}_+$	Tempo de carregamento no porto para viagem t

$$\min \sum_r (\beta_r \cdot h_r + \theta r \cdot (1 - l_r)) \quad (4.1)$$

s.t.

$$\sum_{v \in \mathcal{V} \cup \bar{\mathcal{V}}} x_{p,v}^t \geq \sum_{r \in \rho(t)} Q_r^p \cdot z_t^r \quad \forall p \in P, t \in \mathcal{T} \quad (4.2)$$

$$x_{p,v}^t \leq C_v^p \cdot y_v^t \quad \forall p \in P, t \in \mathcal{T}, v \in \mathcal{V} \cup \bar{\mathcal{V}} \quad (4.3)$$

$$\sum_{t \in \zeta(r)} z_t^r \leq 1 \quad \forall r \in \mathcal{R} \quad (4.4)$$

$$\sum_{v \in \mathcal{V} \cup \bar{\mathcal{V}}} y_v^t \leq 1 \quad \forall t \in \mathcal{T} \quad (4.5)$$

$$\sum_t y_v^t \leq 1 \quad \forall v \in \mathcal{V} \cup \bar{\mathcal{V}} \quad (4.6)$$

$$ETA_v \cdot y_v^t \leq B_t \quad \forall v \in \mathcal{V} \cup \bar{\mathcal{V}}, t \in \mathcal{T} \quad (4.7)$$

$$h_r + \sum_{t \in \zeta(r)} z_t^r = 1 \quad \forall r \in \mathcal{R} \quad (4.8)$$

$$h_r + l_r \leq 1 \quad \forall r \in \mathcal{R} \quad (4.9)$$

$$DD_r \cdot l_r + t_r \geq DD_r \quad \forall r \in \mathcal{R} \quad (4.10)$$

$$M \cdot (l_r - 1) + t_r \leq DD_r \quad \forall r \in \mathcal{R} \quad (4.11)$$

$$t_r \geq tl_{\delta(r)}^t - M \cdot (1 - z_t^r) \quad \forall t \in \zeta(r), r \in \mathcal{R} \quad (4.12)$$

$$t_r \leq tl_{\delta(r)}^t + M \cdot (1 - z_t^r) \quad \forall t \in \zeta(r), r \in \mathcal{R} \quad (4.13)$$

$$tl_{\eta(i)}^t \geq tl_i^t + w_i^t + S_{i,\eta(i)} \quad \forall t \in \mathcal{T}, i \in \kappa(t) \quad (4.14)$$

$$tl_{\alpha(t)}^t \geq B_t + wp^t + S_{porto,\alpha(t)} \quad \forall t \in \mathcal{T} \quad (4.15)$$

$$tl_{\omega(t1)}^{t1} + S_{\omega(t1),porto} + w_{\omega(t1)}^{t1} \leq B_{t2} + M \cdot (2 - y_v^{t1} - y_v^{t2}) \quad \forall v \in \mathcal{V}, (t1, t2) \in \mathcal{T} \times \mathcal{T} \quad (4.16)$$

$$w_c^t \geq \sum_{r \in \rho(t)} (HC_p^c \cdot Q_r^p \cdot z_r^t) \quad \forall t \in \mathcal{T}, c \in \kappa(t) \quad (4.17)$$

$$wp^t \leq UB_t \quad \forall t \in \mathcal{T} \quad (4.18)$$

$$wp^t \geq HP_p \cdot x_{p,v}^t \quad \forall p \in P, t \in \mathcal{T}, v \in \mathcal{V} \quad (4.19)$$

A função objetivo 4.1 procura minimizar o custo total definido pela soma dos custos de não entrega ($\beta_r \cdot h_r$) e dos custos de entrega com atraso ($\theta_r \cdot (1 - l_r)$).

As restrições (4.2) e (4.3) impõem que o fluxo total transportado de produto p na viagem t seja pelo menos igual a soma das quantidades do produto p de cada pedido r alocado na viagem t . Esse fluxo não pode ser maior do que a capacidade do barco v que for designado para esta viagem.

A restrição (4.4) faz com que um pedido r seja alocado a no máximo uma viagem da sua respectiva rota, ao passo que a restrição (4.5) faz com que o mesmo barco não possa ser alocado em mais do que uma viagem por vez. Da mesma forma, a restrição (4.6) impõe que a mesma viagem não possa ser atendida por mais de um barco, enquanto a restrição (4.7) determina que um barco não pode ser alocado numa viagem com abertura de janela para carregamento B_t superior ao tempo de retorno ao fundeio (ETA).

O próximo bloco de restrições trata das medições do nível de serviços e contagem

de tempo. A restrição (4.8) mede se um pedido r foi recusado: se r não foi designado para nenhuma viagem, isso quer dizer que $\sum_t z_r^t = 0$, portanto h_r precisa ser 1. Se um pedido foi recusado, ele também é contado como fora do prazo (4.9). As restrições (4.10 - 4.11) calculam se o pedido foi entregue no prazo, i.e. se $t_r \leq DD_r$, então l_r deve ser 1. Para calcular o tempo de entrega do pedido, utiliza-se as equações (4.12 - 4.13) que determinam que o tempo de entrega do pedido é o mesmo tempo em que o barco chega à unidade.

Para calcular o instante de tempo em que a embarcação chega à unidade marítima utilizamos as restrições (4.14 - 4.15). O tempo de chegada do barco no sucessor da localidade i da rota, definido por $\eta(i)$ é igual ou superior ao tempo em que o mesmo barco chegou à localidade i adicionado aos tempos de viagem e de carregamento. O caso particular a essa regra é o cálculo do tempo de chegada à primeira unidade da rota. O tempo de chegada ao primeiro cliente ($\alpha(t)$) é maior ou igual ao instante em que se inicia o carregamento no berço (B_t) adicionado do tempo de carregamento no porto e do tempo de viagem do porto até o primeiro cliente ($\alpha(t)$).

A restrição (4.16) trata da reutilização dos barcos. Como um barco pode ser designado para uma nova viagem ao retornar, precisamos saber quando este barco estará de volta ao fundeio. Suponhamos que um dado barco v foi alocado para uma viagem t_1 : o momento em que o barco v retorna da viagem é igual ao tempo em que ele chega ao último cliente da rota ($tl_{\omega(t_1)}^t$) acrescido do tempo de carregamento neste cliente ($w_{\omega(t_1)}^{t_1}$) e do tempo de viagem do último cliente de volta para porto ($S_{\omega(t_1),porto}$). O barco clone \bar{v} só poderá ser alocado para uma outra viagem t_2 se e somente se t_2 iniciar seu carregamento num momento posterior ao retorno de v da viagem t_1 dado por ($B_{t_2} \geq tl_{\omega(t_1)}^{t_1} + S_{\omega(t_1),depot} + w_{\omega(t_1)}^{t_1}$). Como não sabemos a priori qual barco fará cada viagem, essa condição não linear é linearizada com o auxílio de um *big M*.

Por fim, temos as restrições que envolvem os tempos de carregamento. Levando em consideração que nas unidades o carregamento acontece de forma sequencial (um produto é movimentado por vez), a restrição (4.17) determina que o tempo de carregamento em cada cliente é maior ou igual a soma dos tempos de carregamento de cada produto $\sum_{r \in \rho(t)} (HC_p^c \cdot Q_r^p \cdot z_r^t)$.

Diferentemente das unidades no porto, temos dois tipos de restrições. A primeira (4.18) é um limite superior no tempo total de carregamento no berço. Além disso, consideramos que as atividades de carregamento no porto, por disponibilidade de infraestrutura podem ocorrer de modo paralelo, isto é, diferentes tipos de produto podem ser carregados simultaneamente, o que resulta na restrição (4.19).

Tabela 4.2: Caracterização das instâncias.

Instância	Rotas	Clientes	Viagens	Barcos	Produtos	Pedidos	Variáveis	Inteiros	Restrições
G5-C30-V3-P1	5	30	2	3	1	172	3,026	2,124	1,902
G5-C30-V3-P2	5	30	2	3	2	388	5,894	4,716	3,544
G5-C30-V3-P3	5	30	2	3	3	477	7,111	5,784	4,297
G5-C30-V3-P4	5	30	2	3	4	709	10,187	8,568	6,051
G5-C30-V6-P1	5	30	2	6	1	172	3,206	2,184	2,388
G5-C30-V6-P2	5	30	2	6	2	388	6,134	4,776	4,150
G5-C30-V6-P3	5	30	2	6	3	477	7,411	5,844	5,023
G5-C30-V6-P4	5	30	2	6	4	709	10,547	8,628	6,897
G10-C60-V8-P4	10	60	2	8	4	1,278	33,734	28,436	15,524
G10-C60-V14-P4	10	60	2	14	4	1,278	35,174	28,676	20,096
G11-C60-V9-P1	11	60	2	9	1	306	11,500	7,740	8,132
G11-C60-V9-P2	11	60	2	9	2	774	23,596	18,972	12,222
G11-C60-V15-P1	11	60	2	15	1	306	12,292	8,004	11,840
G11-C60-V15-P2	11	60	2	15	2	774	24,652	19,236	16,458
G12-C60-V10-P3	12	60	2	10	3	1,053	33,735	27,858	16,993
G12-C60-V17-P3	12	60	2	17	3	1,053	35,415	28,194	23,391
G15-C90-V13-P2	15	90	2	13	2	1,106	45,048	36,172	24,030
G15-C90-V22-P2	15	90	2	22	2	1,106	47,208	36,712	34,848
G16-C90-V14-P3	16	90	2	14	3	1,589	65,887	54,922	32,461
G16-C90-V14-P4	16	90	2	14	4	1,969	80,083	67,842	36,945
G16-C90-V24-P3	16	90	2	24	3	1,589	69,087	55,562	47,201
G16-C90-V24-P4	16	90	2	24	4	1,969	83,923	68,482	52,965
G17-C90-V15-P1	17	90	2	15	1	449	25,827	17,184	24,217
G17-C90-V25-P1	17	90	2	25	1	449	27,867	17,864	37,837
G21-C120-V19-P1	21	120	2	19	1	728	47,670	33,628	44,286
G21-C120-V19-P2	21	120	2	19	2	1,338	76,716	60,468	51,790
G21-C120-V32-P1	21	120	2	32	1	728	50,946	34,720	70,520
G21-C120-V32-P2	21	120	2	32	2	1,338	81,084	61,560	80,208
G22-C120-V20-P3	22	120	2	20	3	2,188	122,240	102,408	67,338
G22-C120-V34-P3	22	120	2	34	3	2,188	128,400	103,640	103,094
G23-C120-V21-P4	23	120	2	21	4	2,744	157,134	133,644	82,072
G23-C120-V36-P4	23	120	2	36	4	2,744	165,414	135,024	126,262

4.2 Geração de instâncias

Quando se trata de problemas reais, uma questão comum quando se publicam resultados e metodologia envolve a utilização informações confidenciais de instituições privadas. Com o objetivo de enfrentar problemas relacionados à confidencialidade dos dados e também para melhorar a reprodutibilidade de nosso trabalho, decidimos criar um conjunto de instâncias que poderiam representar realisticamente o problema comercial original. A partir da análise estatística dos dados obtidos de nosso parceiro de pesquisa, chegamos ao método de geração proposto que será apresentado nesta seção.

De modo geral, o objetivo era utilizar alguns parâmetros iniciais, – como o número total de clientes, quantos clientes compõem uma rota, frequência de atendimento das rotas, o número de embarcações disponíveis e um conjunto de produtos – para a partir deles construir cada instância.

Foi definido que o número de clientes passaria de 30 para 120, com incrementos de 30. Desta forma, foi possível criar problemas de diferentes tamanhos, já que o número de clientes seria a semente que define o número de rotas e embarcações e pedidos. A tabela 4.2 mostra as características de cada instância, as quais têm os

Tabela 4.3: Distribuições de probalidades das instâncias

Parameter	Distribution
Tempo de viagem entre clientes	$lognormal(-0.033, 0.841166)$
Tempo de viagem do porto ao primeiro/último cliente	$logistic(7.4637, 0.6205)$
Início da janela de carregamento no berço	$U[0, (163.8)/frequency]$
Número de pedidos de CG por cliente	$gamma(3, 2)$
Número de pedidos de outros produtos por cliente	$gamma(3.5, 1.8)$
Tamanho do pedido de CG	$1 + gamma(1.5, 2)$
Tamanho do pedido por outros produtos	$1 + gamma(4, 0.35)$
Prazo de entrega do pedido	$-84 + 340 \cdot beta(2.1, 1.5)$
ETA do barco	$84 \cdot beta(1.5, 3)$
Capacidade do barco para CG	$poisson(80)$
Capacidade do barco para os demais produtos	$500 + 1000 \cdot beta(4, 2)$

seus nomes estruturados como $G\{\text{number of routes}\} - C\{\text{number of customers}\} - V\{\text{number of boats}\} - P\{\text{number of products}\}$ número de produtos. Além disso, a mesma tabela descreve o tamanho do modelo matemático equivalente à instância com os números totais de variáveis, de variáveis inteiras, e restrições.

Definimos um conjunto de quatro produtos diferentes, de modo que o primeiro produto da lista será sempre tratado como Carga Geral, enquanto os demais representam um fluido genérico (água, diesel, etc.). Seguimos esta estratégia porque a carga geral opera numa ordem de grandeza diferente dos produtos líquidos (algumas dezenas de unidades contra milhares de metros cúbicos), além disso, a carga geral é manuseada com guindastes, o que resulta em diferentes distribuições do tempo de transferência.

Durante a rotina de construção da instância, frequentemente usamos distribuições de probabilidade (Tabela 4.3) para sortear valores. Estas distribuições foram obtidas a partir da análise estatística e do ajuste da distribuição dos dados reais. Essas distribuições não são exatamente as mesmas utilizadas no capítulo 3. Durante a simulação, diversas vezes, o modelo de otimização recebia uma instância de parâmetros para construção e resolução do modelo matemático, de modo que, com base nessas instâncias, foram ajustadas as distribuições de probabilidade de cada parâmetro do modelo matemático.

4.2.1 Geração de rotas

Não estamos interessados em resolver um problema de roteamento. Como o planejamento de rotas é decidido em nível mais estratégico, trabalhamos com rotas pré-definidas. Para simular esta condição, cada rota é definida pelo desenho de um conjunto aleatório de clientes únicos com tamanho entre 4 e 7. Se qualquer rota tiver menos clientes que o mínimo exigido (geralmente acontece com a última construída), uma simples heurística trocará com outras rotas até que seja encontrado

Tabela 4.4: Exemplo de conjunto de rotas para instâncias com 10 clientes, 4 rotas e dois clientes atendidos por rota

Route	Bert Time	1 st Trip	2 nd Trip	Clients Sequence	Sail Times
0	14.0	53.0	137.0	[0, 6, 5]	[8.0, 0.647, 0.27, 9.06]
1	14.0	12.0	96.0	[1, 2]	[6.19, 2.34, 9.19]
2	14.0	2.0	86.0	[8, 7]	[8.47, 0.402, 6.99]
3	14.0	15.0	99.0	[9, 3, 4]	[6.87, 0.5, 0.64, 5.53]

um arranjo viável.

Os tempos de viagem entre clientes de rota são desenhados com uma distribuição log-normal, enquanto os tempos de viagem entre o porto e o primeiro e último clientes da rota seguem uma distribuição logística.

As janelas de tempo de atracação para cada rota também são construídas a partir da frequência semanal de viagem. Consideramos, portanto, que as viagens são igualmente espaçadas ao longo da semana. Se em uma semana de 168 horas houver 2 viagens, por exemplo, então cada uma terá 84 horas de intervalo. Neste exemplo, a hora da primeira viagem é traçada com distribuição uniforme $U[0, (168)/2]$ e o tempo da segunda viagem é igual ao primeiro valor adicionado de 84 horas. Portanto, ao montar uma programação em que realizam n viagens por semana, sorteamos os horários de início de janela de berço correspondentes ao primeiro atendimento de cada rota com uma distribuição uniforme entre $[0, 168/n]$ e duplicamos estes horários com seus pares adicionados em 84 horas.

4.2.2 Geração de pedidos

O primeiro passo para a construção do conjunto de pedidos é desenhar quantos pedidos para cada tipo de produto serão feitos por cada cliente. Como discutido no início desta seção, os pedidos da GC têm uma escala muito diferente. Portanto, usamos duas distribuições gama distintas (Tabela 4.3): uma para sortear a quantidade de pedidos de carga geral e outra para os outros produtos, se houver.

Com as quantidades dos pedidos definidas, podemos amostrar a quantidade de produto que foi solicitada em cada pedido e sua data de entrega. As datas de entrega seguem uma distribuição beta modificada com parâmetros $(-84; 252)$, tendo a distribuição sido modelada desta forma para que tenhamos tanto os pedidos que já expiraram - data negativa - quanto pedidos com prazo alongado - após a semana de planejamento.

4.2.3 Geração de barcos

O número de embarcações é um parâmetro que foi construído a partir do número de clientes. Esperávamos que o número de embarcações disponíveis influenciasse o tempo de resolução do modelo matemático. Devido a isso, para cada cliente e conjunto de dados do pedido produzido nas etapas anteriores, foi estimado um número mínimo e máximo de embarcações. Se n_k é o número total de rotas que foram criadas, o número de embarcações que serão utilizadas pertence ao conjunto $\{\lfloor 0.3 \cdot n_k^{1.2} \rfloor, \lfloor 0.4 \cdot n_k^{1.2} \rfloor, \lfloor 0.5 \cdot n_k^{1.2} \rfloor\}$. Para cada embarcação, seus atributos são então calculados: hora de chegada ao porto e capacidades para cada produto.

O tempo de chegada segue uma distribuição beta modificada de parâmetros $(1.5, 3)$, garantindo que o navio pode estar ancorado ($ETA = 0$) ou chegar dentro de 3 dias e meio (84 horas).

4.3 Experimentos computacionais

O problema de planejamento de embarcações multiproduto com seleção de pedidos e janelas de tempo é uma generalização do *Generalized Assignment Problem* (GAP). Considerando um caso especial em que existe uma única configuração viável de par de viagem-barco, o problema resultante da seleção de pedidos reduz-se a uma instância do GAP que é fortemente NP-Hard como provado pela FISHER *et al.* (1986). Isto, por si só, já indica que o problema estudado nesta tese cresce em dificuldade para ser resolvido muito rapidamente com o tamanho da instância e os experimentos com modelos matemáticos reforçam esta afirmação.

Nesta seção apresentaremos um conjunto de experimentos computacionais feitos com o modelo matemático a fim de verificar experimentalmente as afirmações do parágrafo anterior. Esses resultados servirão também como *benchmark* para a análise do desempenho de métodos heurísticos que serão apresentados no próximo capítulo.

Todos os experimentos deste capítulo foram feitos em instâncias na *Google Cloud Platform* do tipo n1-standard-4, sistema operacional Ubuntu, 20.04 LTS, processador 2 Intel(R) Xeon(R) CPU @ 2.30GHz cores (4 threads), 15 GB de memória RAM e o *solver* comercial em licença acadêmica Gurobi 8.1.1. Os modelos foram implementados utilizando a API nativa do Gurobi para *python* com o parâmetro de limite de *threads* igual a 1.

Foi utilizado um conjunto de 32 instâncias produzidas com a metodologia proposta na seção 4.2. Essas instâncias representam o problema de forma realista e possuem tamanhos variando desde configurações menores do que a operada no E&P brasileiro quanto muito maiores, as quais podem ser encontradas na íntegra em SEIMETZ CHAGAS e FERREIRA FILHO (2021). Resumimos na tabela 4.5 os

Tabela 4.5: Resultados obtidos com o solver comercial para as 32 instâncias

Instância	Objetivo	LB	Gap(%)	Cpu(s)
G5-C30-V3-P1	290.25	290.25	0.00%	36.67
G5-C30-V3-P2	1,144.95	1,144.95	0.00%	343.40
G5-C30-V3-P3	1,898.89	1,898.89	0.00%	337.10
G5-C30-V3-P4	2,488.87	2,472.06	0.70%	1,800
G5-C30-V6-P1	135.98	135.98	0.00%	89.17
G5-C30-V6-P2	792.12	776.78	1.90%	1,800
G5-C30-V6-P3	1,301.59	1,265.57	2.80%	1,800
G5-C30-V6-P4	2,197.51	2,028.09	7.70%	1,800
G10-C60-V8-P4	4,402.37	3,826.43	13.10%	1,800
G10-C60-V14-P4	3,860.18	3,487.32	9.70%	1,800
G11-C60-V9-P1	242.98	238.48	1.90%	1,800
G11-C60-V9-P2	2,005.2	1,922.1	4.10%	1,800
G11-C60-V15-P1	256.1	251.3	1.90%	1,800
G11-C60-V15-P2	1,740.14	1,689.99	2.90%	1,800
G12-C60-V10-P3	3,052.19	2,599.42	14.80%	1,800
G12-C60-V17-P3	2,736.6	2,365.68	13.60%	1,800
G15-C90-V13-P2	2,780.76	2,622.82	5.70%	1,800
G15-C90-V22-P2	2,760.31	2,657.67	3.70%	1,800
G16-C90-V14-P3	4,964.66	4,224.15	14.90%	1,800
G16-C90-V14-P4	6,447.86	5,541.36	14.10%	1,800
G16-C90-V24-P3	4,364.61	3,958.9	9.30%	1,800
G16-C90-V24-P4	5,986.9	5,104.09	14.70%	1,800
G17-C90-V15-P1	269.85	218.11	19.20%	1,800
G17-C90-V25-P1	231.67	214.28	7.50%	1,800
G21-C120-V19-P1	591.63	544.59	8.00%	1,800
G21-C120-V19-P2	2,981.03	2,579.89	13.50%	1,800
G21-C120-V32-P1	700.33	592.07	15.50%	1,800
G21-C120-V32-P2	2,612.37	2,415.91	7.50%	1,800
G22-C120-V20-P3	6,434.25	5,522.62	14.20%	1,800
G22-C120-V34-P3	5,561.53	5,048.72	9.20%	1,800
G23-C120-V21-P4	9,012.82	7,334.38	18.60%	1,800
G23-C120-V36-P4	8,114.45	6,981.7	14.00%	1,800

resultados obtidos com a formulação.

4.4 Conclusões

Considerando que muitos casos não puderam ser resolvidos até o ótimo mesmo com horas de processamento, estabelecemos um tempo de referência de 30 minutos como um período de tempo razoável que um tomador de decisão aceitaria esperar por uma solução suficientemente boa.

Já nas instâncias de menor tamanho, com apenas 5 rotas e 30 clientes, podemos verificar que o solver começa a ter dificuldades de chegar a uma solução comprovadamente ótima. Nenhum caso com mais do que 5 rotas conseguiu encontrar o ótimo dentro do tempo limite e os *gaps* ficam progressivamente maiores.

Se observarmos a evolução dos limitantes ao longo do processamento pela figura 4.1, podemos ver que ambos os limitantes iniciam-se em valores triviais e convergem



Figura 4.1: Limitantes superior e inferior para cada instância vs tempo de processamento

rapidamente para zonas planas. O modelo possui muitas restrições linearizadas com o recurso de modelagem com big M, as quais levam à relaxações fracas. Os gráficos mostram que, em muitos casos, uma nova solução é encontrada em fase avançada do processamento.

Os resultados de referência obtidos nesta seção serão utilizados como métrica para avaliar o desempenho dos métodos heurísticos apresentados no próximo capítulo.

Capítulo 5

Metaheurísticas e algoritmos híbridos

Como demonstrado no final do Capítulo 4, resolver instâncias maiores tornou-se um desafio do ponto de vista do tempo de processamento. Nesse caso, uma abordagem natural é considerar a utilização de soluções heurísticas para o problema.

Abordagens heurísticas sacrificam a busca pela comprovação de otimalidade da solução em troca de obter boas soluções viáveis mais rapidamente. De um ponto de vista de utilidade prática, essa abordagem é bastante atraente para a natureza de aplicação do problema estudado, uma vez que o tomador de decisão está mais interessado em obter soluções de boa qualidade de forma rápida do que em possuir confiança de que está perto do ótimo global. A análise da evolução dos limitantes do modelo matemático feita no capítulo anterior aponta que a busca por soluções viáveis de melhor qualidade é um campo de exploração promissor para o problema.

Estudaremos dois tipos de implementação de heurísticas. A primeira é baseada na metaheurística *Adaptive Large Neighborhood Search* (ALNS), enquanto a segunda é com base em heurísticas construtivas híbridas, também conhecidas na literatura como *matheuristics*, do tipo *Relax-and-Fix*, que misturam técnicas heurísticas com a resolução de modelos matemáticos.

5.1 Estrutura de solução e vizinhança

Uma solução viável do Problema de Alocação de Cargas pode ser dividida em duas partes. Na primeira, decidimos uma alocação de barcos e viagens; na segunda, quais pedidos serão alocados nos barcos escolhidos para cada viagem. Podemos definir, portanto, um vetor de tamanho $|T|$, sendo T o conjunto de viagens, em que cada elemento desse vetor será o barco alocado para essa viagem e o valor -1 atribuído no caso em que não foi alocado barco nenhum para a respectiva viagem.

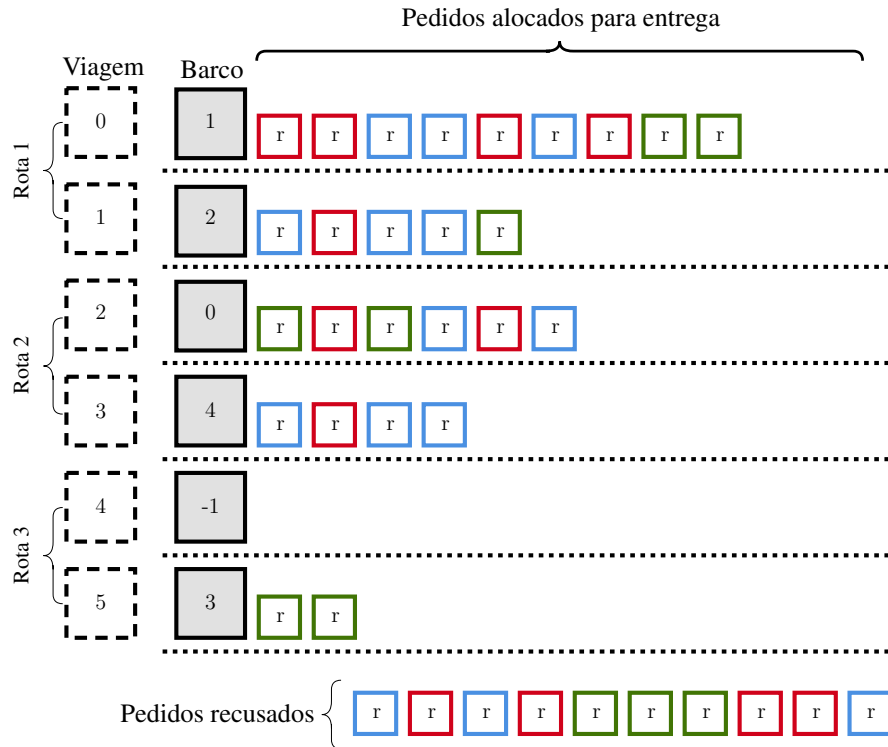


Figura 5.1: Representação da Estrutura de solução

Com a alocação barco-viagem definida, os pedidos devem ser distribuídos entre suas respectivas viagens. Nessa etapa é preciso atentar para que não sejam violadas algumas restrições do problema: i) tempo de carregamento no berço; ii) capacidade da embarcação para cada tipo de produto; e iii) tempo de retorno do barco, caso ele seja reutilizado para outra viagem dentro do mesmo período de planejamento.

A Figura 5.1 representa essa estrutura de solução. Os blocos pontilhados representam viagens, com destaque para o fato de que viagens do mesmo grupo de unidades são consecutivas. Ao lado, em tom cinza, temos a alocação de barcos das viagens. No exemplo, a primeira viagem do terceiro grupo de unidades não teve nenhum barco agendado para realizá-la. Além disso, em cada barco foram alocados pedidos que tinham clientes de cada grupo como destinatário. Por fim, as cores representam diferentes produtos e a pilha de produtos na parte inferior representa pedidos que não foram alocados.

Com a definição da estrutura de uma solução viável do problema, resta agora definir como passear entre soluções vizinhas, etapa fundamental em qualquer metaheurística que se baseie em heurísticas de busca local. A Figura 5.2 apresenta como pode ocorrer essa busca. Tanto pedidos do mesmo produto podem ser trocados entre viagens - se continuarem produzindo soluções viáveis - quanto barcos não alocados podem ser introduzidos, permitindo uma nova leva de alocação de pedidos.

É fácil perceber que, pela própria estrutura da solução do problema, temos uma estratégia natural de intensificação que consiste em procurar a melhor alocação de

A heurística *relax-and-fix* é um método construtivo baseado no particionamento do conjunto de variáveis inteiras do problema com o intuito de resolver sequencialmente uma série de problemas menores e de solução mais rápida. Esses problemas são construídos relaxando a restrição de integralidade em um subconjunto das variáveis inteiras. Em cada iteração do algoritmo, utilizamos as soluções obtidas dos subproblemas anteriores como valores fixos e esse processo é repetido até que, com o fim da última iteração, uma solução viável terá sido construída.

Como demonstrado em ABSI e VAN DEN HEUVEL (2019), um elemento chave ao implementar uma heurística *relax-and-fix* é a estratégia para a decomposição de subconjuntos de variáveis inteiras. O problema estudado nesta tese favorece a implementação da heurística *relax-and-fix* dada a sua estrutura fortemente decomponível. Cada rota é definida por um par de viagens. Esse conjunto de viagens possui uma sequência de clientes que também é conhecida e cada cliente possui sua lista de pedidos. Além disso, os horários agendados para o carregamento de cada viagem no porto (B_t) não é compatível com todos os barcos, visto que alguns só ficam disponíveis no fundeio depois desse horário, fazendo com que apenas um subconjunto dos barcos esteja apto a realizar as entregas de cada rota. Portanto, cada rota pode ter o problema de alocação de pedidos resolvido independentemente para uma determinada alocação de barcos.

Para decidir como alocar os barcos, propomos duas abordagens: i) incluir a decisão de escolha do barco no subproblema; ou ii) resolver a alocação de barcos para todas as viagens como um problema individual.

No primeiro caso, a heurística consiste em resolver inicialmente a relaxação linear do problema. Depois disso, iteramos cada rota criando um subproblema no qual a integralidade das variáveis de atribuição de pedidos e de atribuição de embarcações é restaurada (apenas para a rota da vez), de modo que esta redução das variáveis inteiras¹ permite que o modelo resultante possa ser resolvido muito mais rapidamente do que o original. Com esta parte da solução feita, podemos passar para a rota seguinte. Desta vez, porém, mantemos a solução anterior fixa à medida que restabelecemos a integralidade para um novo conjunto de variáveis. Chamaremos esta heurística de *relax-and-fix* baseado em rotas (RF-Routes) - Algoritmo 1.

O segundo método consiste em dividir o problema em duas fases. Primeiro, resolvemos o subproblema em que apenas as variáveis de alocação de barcos são inteiras, enquanto as variáveis de alocação de pedidos são relaxadas. O passo seguinte é fixar as variáveis de atribuição de barcos e resolver a seleção de pedidos para cada rota separadamente, de maneira que apenas as variáveis relacionadas com a rota têm a sua integralidade restaurada. Esta heurística será chamada de *relax-and-fix* de dois estágios (RF-2S) - Algoritmo 2.

¹A notação utilizada nas heurísticas é a mesma apresentada na Tabela 4.1 do capítulo 4

Idealmente, ambos os métodos deveriam decompor o problema original em problemas menores consideravelmente mais rápido, resultando num tempo total baixo para a obtenção de boas soluções. Contudo, como será visto adiante na seção de experimentos computacionais, a escolha da forma de decomposição do problema pode produzir grande diferença de resultados.

Algoritmo 1: Heurística *Relax-and-Fix* baseada em rotas (RF-Routes)

```

1 relaxar todas as variáveis inteiras;
2 resolver o problema relaxado;
3 for  $g \in \mathcal{G}$  do
4   for  $r \in \mathcal{R}$  se  $\delta(r) \in g$  do
5     | restaurar a integralidade de  $l_r$  e  $h_r$ ;
6     | restaurar a integralidade de  $z_t^r \forall t \in \mathcal{T}$ ;
7   end
8   for  $t \in \mathcal{T}$  se  $\kappa(t) = g$  do
9     | restaurar a integralidade de  $y_v^t \forall v \in \mathcal{V}$ ;
10  end
11  resolver o subproblema da rota  $g$ ;
12  for  $r \in \mathcal{R}$  se  $\delta(r) \in g$  do
13    | fixar as soluções de  $l_r$  e  $h_r$ ;
14    | fixar as soluções de  $z_t^r \forall t \in \mathcal{T}$ ;
15  end
16  for  $t \in \mathcal{T}$  se  $\kappa(t) = g$  do
17    | fixar as soluções de  $y_v^t \forall v \in \mathcal{V}$ ;
18  end
19  relaxar todas as variáveis inteiras;
20 end
21 restaurar a integralidade de todas as variáveis;
22 resolver o problema;
23  $s^*$  = solução do modelo;
24 return  $s^*$ 

```

5.3 Adaptive Large Neighborhood Search - ALNS

A metaheurística ALNS tem sua origem nos trabalhos de PISINGER e ROPKE (2007); ROPKE e PISINGER (2006a,b). Essa metaheurística surge como uma evolução do *Large Neighborhood Search* (LNS). Durante alguns anos os trabalhos seminais permaneceram como as principais publicações a respeito do tema, mas a partir dos anos 2010, a metaheurística começou a ganhar notoriedade devido seu desempenho em trabalhos relacionados a roteamento de veículos (CONTARDO *et al.*, 2012; CUESTA *et al.*, 2017b; LAPORTE *et al.*, 2010; RIBEIRO e LAPORTE, 2012; RIBEIRO *et al.*, 2014) e coleta e entrega (GHILAS *et al.*, 2016; GRIMAULT *et al.*, 2017; MASSON *et al.*, 2013; QU e BARD, 2012).

Não se restringindo a problemas da classe de roteamento de veículos a metaheurística ALNS já foi aplicada numa grande variedade de problemas como os que

Algoritmo 2: Heurística *Relax-and-Fix* de dois estágios (RF-2s)

```
1 relaxar todas as variáveis inteiras;
2 for  $t \in \mathcal{T}$  do
3   | for  $v \in \mathcal{V}$  do
4   |   | restaurar a integralidade de  $y_v^t \forall v \in \mathcal{V}$ ;
5   | end
6 end
7 resolver o subproblema de alocação de barcos;
8 fixar as soluções de alocação de barcos;
9 for  $g \in \mathcal{G}$  do
10  | for  $r \in \mathcal{R}$  se  $\delta(r) \in g$  do
11  |   | restaurar a integralidade de  $l_r$  e  $h_r$ ;
12  |   | restaurar a integralidade de  $z_t^r \forall t \in \mathcal{T}$ ;
13  | end
14  | resolver o subproblema de seleção de pedidos;
15  | for  $r \in \mathcal{R}$  se  $\delta(r) \in g$  do
16  |   | fixar as soluções de  $l_r$  e  $h_r$ ;
17  |   | fixar as soluções de  $z_t^r \forall t \in \mathcal{T}$ ;
18  | end
19  | relaxar todas as variáveis inteiras;
20 end
21 restaurar a integralidade de todas as variáveis;
22 resolver o problema;
23  $s^*$  = solução do modelo;
24 return  $s^*$ 
```

listamos a seguir de forma não exaustiva: *Lot-sizing* MULLER *et al.* (2012); *time tabling* BARRENA *et al.* (2014); KIEFER *et al.* (2016); KRISTIANSEN e STIDSEN (2014); KRISTIANSEN *et al.* (2013); LI *et al.* (2019); programação de guindastes GHAREHGOZLI *et al.* (2015); *network design* CANCA *et al.* (2017, 2019); CHEN *et al.* (2014); HASANI e KHOSROJERDI (2016); MOHRI *et al.* (2018); SCHIFFER e WALTHER (2018); STEADIESEIFI *et al.* (2017); SÁ *et al.* (2015); programação de berços IRIS *et al.* (2017); MAURI *et al.* (2016); RIBEIRO *et al.* (2016); problemas de transporte LEE *et al.* (2016); MASSON *et al.* (2015, 2016); ZIEBUHR e KOPFER (2014, 2016)

O mecanismo principal da metaheurística ALNS consiste em aplicar repetidamente operadores de destruição e reparo a uma solução corrente do problema para a produção de vizinhanças largas o bastante para explorar o espaço de soluções fugindo de ótimos locais. Sua inovação comparativamente ao LNS está na possibilidade de usar diversos operadores de destruição e reparo, que são escolhidos a cada iteração com base no seu desempenho recente, fazendo com que a metaheurística "adapte-se" buscando o melhor par de operadores a todo momento.

Para conseguir uma maior diversidade de soluções, os métodos de destruição costumam ter certo grau de aleatoriedade na escolha de elementos da solução que serão removidos. Por outro lado, um balanço entre aleatoriedade e estratégia gulosa é essencial para evitar ficar ciclando de volta para a mesma solução, enquanto se

procura aprimorar o resultado escapando de pontos subótimos. Esses *tradoffs* foram mais profundamente avaliados em HEMMATI e HVATTUM (2016).

A estrutura do ALNS implementado segue como descrito no Algoritmo 3. Partindo-se de uma solução inicial s , inicializam-se os vetores ρ^d e ρ^r , que são respectivamente os pesos de cada um dos operadores de destruição e reparação implementados. Enquanto o critério de parada não for satisfeito, um método de destruição é sorteado aleatoriamente - utilizando-se, usualmente, o método da roleta - e, com ele, um pedaço da solução é destruído.

Na sequência, um operador de reparação é sorteado e uma nova solução é construída a partir dele, complementando a solução que havia sido parcialmente destruída. Essa solução é aceita de acordo com algum critério. (SANTINI *et al.*, 2018) estudou diferentes critérios de aceitação e concluiu que a escolha do critério de aceitação possui relevância estatística no desempenho final da heurística em determinados problemas.

Com uma nova solução em mãos, avaliamos o desempenho dos operadores e seus pesos são atualizados. Seguimos os mesmos critérios de pontuação apresentados em CORDEAU *et al.* (2011), de forma que cada par de heurísticas de reparação e destruição é atualizado com uma pontuação Ψ dada por:

$$\Psi = \begin{cases} \omega_1 = 10 & \text{se a nova solução é o novo ótimo global} \\ \omega_2 = 5 & \text{se a nova solução é melhor do que a atual} \\ \omega_3 = 3 & \text{se a nova solução é pior mas é aceita} \\ \omega_4 = 1 & \text{se a nova solução é rejeitada} \end{cases}$$

Dessa forma, os pesos ρ^d e ρ^r são atualizados como $\rho^d = \lambda\rho^d + (1 - \lambda)\Psi$ e $\rho^r = \lambda\rho^r + (1 - \lambda)\Psi$, em que $\lambda \in [0, 1]$ é um parâmetro que regula o quanto de peso será atribuído ao histórico de desempenho da heurística. Se $\lambda \rightarrow 1$, o primeiro resultado fica valendo sempre; por outro lado, se $\lambda \rightarrow 0$, estamos sempre priorizando o desempenho mais recente.

5.3.1 Construção da solução inicial

Para a construção da solução inicial do problema, propomos duas abordagens: uma solução inicial gulosa randomizada e uma solução aleatória.

Na solução gulosa randomizada (Algoritmo 4), primeiramente os pedidos são ordenados por volume (ordem crescente), já que queremos priorizar o atendimento da maior quantidade de pedidos. Para cada viagem, um barco dentre os disponíveis é escolhido aleatoriamente. Esse barco, na sequência, é preenchido com o máximo de pedidos de cada produto suportados por sua capacidade.

Na construção aleatória (Algoritmo 5), barcos são selecionados aleatoriamente para as viagens e preenchidos com pedidos também selecionados de forma aleatória.

Algoritmo 3: Adaptive Large Neighborhood Search

```
1  $s$  = Solução viável inicial;
2  $\rho^d = (1, \dots, 1)$ ;  $\rho^r = (1, \dots, 1)$ ;
3 while Critério de parada não atingido do
4   | selecionar operadores de destruição e reparação com pesos  $\rho^d$  e  $\rho^r$ ;
5   |  $s' = \text{repair}(\text{destroy}(s))$ ;
6   | if Aceitação( $s^*$ ,  $s'$ ) then
7   |   |  $s = s'$ ;
8   | end
9   | if  $f(s') < f(s^*)$  then
10  |   |  $s^* = s'$ ;
11  | end
12  | atualizar  $\rho^d$  e  $\rho^r$ 
13 end
14 return  $s^*$ 
```

Algoritmo 4: Solução gulosa randomizada

```
1  $Undelivered$  = Pedidos ordenados por quantidade crescente;
2  $FreeVessels = V$ ; // Barcos disponíveis
3 for  $t \in T$  do
4   | criar  $VesselCandidates \subset BarcosLivres$ ; // barcos compatíveis com  $t$ 
5   | if  $VesselCandidates \neq \emptyset$  then
6   |   | sortear  $v \in VesselCandidates$  compatível  $t$ ;
7   |   | for  $r \in R$  do
8   |   |   | if  $r$  compatível com  $t$  e  $v$  then
9   |   |   |   | alocar  $r$  em  $v$ ; // respeitando o limite de capacidade e janela
10  |   |   |   | de tempo no berço
11  |   | end
12  |   | remover  $v$  de  $FreeVessels$ ;
13 end
```

5.3.2 Operadores de destruição e reparação

Nesta subseção são descritos os nove métodos de destruição implementados. Pela própria estrutura do problema, existem duas classes principais de perturbação: a de barcos e a de pedidos. Na primeira, removemos um conjunto de barcos alocados para realizar viagens e, junto com eles, todos os seus pedidos. Já na segunda, os barcos são mantidos e apenas uma fração dos pedidos é removida. Desta maneira, espera-se que, ao remover barcos, seja possível explorar uma diversidade maior de soluções, enquanto que ao se remover pedidos, a busca por soluções localmente melhores seja intensificada.

Os operadores de destruição recebem um parâmetro α que determina a fração de barcos ou de pedidos alocados que deve ser removida da solução por meio do operador. Listamos abaixo os operadores de destruição implementados:

- **Remoção aleatória de barcos:** Uma fração α de barcos alocados em viagens é retirada da solução.

Algoritmo 5: Solução inicial aleatória

```
1 PedidosDisponiveis = R;
2 BarcosLivres = V ; // Barcos disponíveis
3 for t ∈ T do
4   criar Compativeis ⊂ BarcosLivres ; // Barcos compatíveis com t
5   if Compativeis ≠ ∅ then
6     sortear v ∈ BarcosLivres compatível com t;
7     while v não estiver cheio do
8       | Sorteia um pedido r ∈ PedidosDisponiveis;
9     end
10    remover v de BarcosLivres;
11 end
```

- **Remoção do barco mais ocioso:** Os barcos alocados em viagens são ordenados do mais vazio para o mais cheio e os primeiros mais vazios são retirados
- **Remoção de Shaw de barcos:** Remover um conjunto de barcos semelhantes usando um critério de semelhança inspirado no proposto em SHAW (1998). Um par de barcos v_1 e v_2 possuem um grau de semelhança $relatedness = |ETA_{v_1} - ETA_{v_2}| + \sum_p (|C_{v_1}^p - C_{v_2}^p|)$. Os pares que apresentam maior valor de $relatedness$ são removidos juntos.
- **Remoção aleatória de pedidos:** Uma fração α de pedidos alocados em viagens é retirada da solução.
- **Remoção dos maiores pedidos:** Os pedidos alocados em viagens são ordenados em ordem de volume e os maiores são removidos.
- **Remoção dos pedidos mais baratos:** Os pedidos são ordenados em ordem de custo de não entrega e os mais baratos são removidos.
- **Remoção dos pedidos com maior razão volume/custo:** Os pedidos são ordenados em ordem crescente da razão volume por custo de não entrega ($Q_r^p/\beta(r)$) e os de maior razão são removidos.
- **Remoção de Shaw de pedidos:** Remover um conjunto de pedido semelhantes usando um critério de semelhança. Um par de pedidos r_1 e r_2 possuem um grau de semelhança

$$relatedness = |DD_{r_1} - DD_{r_2}| + |Q_{r_1}^p - Q_{r_2}^p| + M \cdot \begin{cases} 0 & \text{se } r_1 \text{ e } r_2 \text{ mesmo produto} \\ 1 & \text{outro caso} \end{cases}$$

Assim como para a destruição, os métodos de reparação dividem-se em dois grupos principais: barcos e pedidos. Listamos abaixo os operadores de reparação implementados:

- **Reparação de barcos aleatória:** Barcos disponíveis para a viagem são selecionados aleatoriamente.
- **Reparação do maior barco:** Os maiores barcos disponíveis são selecionados.
- **Reparação de barco com maior ETA:** Os barcos com maior ETA são selecionados.
- **Reparação aleatória de pedidos:** Pedidos disponíveis para viagem são selecionados aleatoriamente.
- **Reparação do menor pedido:** Os menores pedidos são selecionados primeiro.
- **Reparação dos pedidos mais caros:** Os pedidos com maior custo de não entrega são selecionados primeiro.
- **Reparação dos pedidos com maior razão custo/volume:** Os pedidos que possuírem a maior razão custo de não entrega por volume ($\beta(r)/Q_r^p$) são selecionados para reparação.
- **Reparação dos pedidos via modelo matemático:** Como apenas uma fração dos pedidos precisa ser reparada, resolver a realocação de pedidos via modelo matemático fixando todas as demais variáveis da solução é uma alternativa. Embora custoso computacionalmente, pode produzir soluções de boa qualidade.

5.4 Uma implementação ramificada do ALNS

Uma implementação direta do ALNS pode não ser a escolha mais eficiente para resolver o problema, visto que este possui uma decomposição muito clara de sua solução. Barcos precisam ser alocados em viagens, independentemente de quais pedidos irão levar. Os pedidos, por sua vez, só podem ser alocados no barco se existir capacidade para isso. Selecionar aleatoriamente qual parte da solução será destruída e escolher, também de forma aleatória, qual será reparada pode ser muito ineficiente se todos os operadores forem tratados de forma equivalente.

Ao remover pedidos, não faz sentido reparar barcos e vice-versa. Iterações que passarem por esse tipo de cenário são desperdício de recurso computacional e devem ser evitadas de alguma forma. Considerando isto, propomos uma implementação nova do ALNS que contemple essa estrutura do problema e esperamos que dessa maneira, resultados melhores possam ser obtidos.

O Algoritmo 6 apresenta o conceito geral do que chamamos de ALNS-ramificado. O algoritmo inicia-se da mesma forma que o Algoritmo 3, com a produção de uma solução inicial. Em seguida, um método de roleta seleciona qual classe de operador será utilizada (barcos ou pedidos) para a destruição. Em função da classe escolhida, os operadores de destruição e reparo para esta classe serão sorteados também com um método de roleta. A cada iteração os pesos dos operadores e das classes de operadores são atualizados com o mesmo critério de pontuação utilizado no Algoritmo 3.

Algoritmo 6: Branched Adaptive Large Neighborhood Search

```

1  $s$  = Solução viável inicial;
2  $\rho_c = (1, 1)$ ;  $\rho_c^d = (1, \dots, 1)$ ;  $\rho_c^r = (1, \dots, 1)$ ;
3 while Critério de parada não atingido do
4   | selecionar classe do operador com pesos  $\rho^c$ ;
5   | selecionar operadores de destruição e reparação para a classe  $c$  com pesos  $\rho_c^d$  e  $\rho_c^r$ ;
6   |  $s' = \text{repair}(\text{destroy}(s))$ ;
7   | if Aceitação( $s^*$ ,  $s'$ ) then
8     |   |  $s = s'$ ;
9     | end
10  | if  $f(s') < f(s^*)$  then
11    |   |  $s^* = s'$ ;
12    | end
13  | atualizar  $\rho_c^d$  e  $\rho_c^r$ 
14 end
15 return  $s^*$ 

```

5.5 Experimentos computacionais

Nesta seção apresentaremos um conjunto de experimentos computacionais feitos com as heurísticas e metaheurísticas implementadas. Nosso objetivo é avaliar o desempenho delas comparativamente ao modelo matemático e descobrir se logram êxito em prover soluções tão boas ou melhores em menor tempo computacional. Esses experimentos foram aplicados nas mesmas 32 instâncias que o modelo matemático.

Assim como no capítulo 4, todos os experimentos deste capítulo foram feitos em instâncias na *Google Cloud Platform* do tipo n1-standard-4, sistema operacional Ubuntu, 20.04 LTS, processador 2 Intel(R) Xeon(R) CPU @ 2.30GHz cores (4 *threads*), 15 GB de memória RAM e o *solver* comercial em licença acadêmica Gurobi 8.1.1. Os modelos foram implementados utilizando a api nativa do Gurobi para *python* com o parâmetro de limite de *threads* igual a 1.

5.5.1 Resultados obtidos com a heurística Relax-and-Fix

Para assegurar uma comparação justa, o *relax-and-fix* também tem uma limitação de tempo. Cada subproblema teve seu tempo limitado em 1800s/(número de rotas). Um ponto fraco desta abordagem é que as instâncias maiores terão menos tempo de processamento para cada rota. Como consequência deste menor tempo de processamento por rota em instâncias maiores, a heurística pode ter dificuldade em alcançar uma solução viável antes do fim do limite de tempo. Para evitar este problema, a etapa de resolução do subproblema é dividida em duas partes. Primeiro será esperado o tempo necessário para a primeira solução, em seguida, o modelo pode continuar a ser resolvido se ainda houver tempo disponível. Como resultado desta abordagem, podemos ver que em alguns casos o heurística pode ultrapassar o tempo gasto pelo *solver*.

Para auxiliar na visualização dos resultados, elaboramos a Figura 5.3. Nela podemos ver a performance relativa das heurísticas para cada uma das instâncias. As barras verdes representam a razão entre a melhor solução encontrada pela heurística e a melhor solução obtida pelo *solver* comercial. As barras laranja representam a razão entre o tempo de CPU gasto pelas heurísticas e o tempo gasto pelo *solver* comercial. A linha tracejada no eixo vertical de valor constante 1 representa o valor obtido pelo *solver*, isto é, quando as barras estiverem abaixo significa que a heurística obteve uma solução melhor ou foi mais rápida que o *solver*.

Observando a Figura 5.3 podemos ver que o *Relax-and-fix* baseado em rotas (RF-Routes) foi bem sucedido em produzir soluções relativamente próximas das obtidas pelo modelo, quando não melhores, e quase sempre em tempo inferior. As soluções da heurística são, em média, 4,6% piores do que as obtidas pelo *solver*, apesar de conseguirem ter obtido melhores resultados em 9 instâncias, com esses resultados tendo sido obtidos com 52,5% menos tempo de processamento.

Destacamos as exceções para as instâncias G21-C120-V32-P2, G22-C120-V34-P3 and G23-C120-V36-P4. Nesses casos, o RF-Routes excedeu o tempo de processamento limite, não tendo sido maior que 3,1% o tempo adicional incorrido nas duas primeiras.

A heurística *relax-and-fix* de dois estágios (RF-2S) apresentou performance consideravelmente superior a da versão baseada em rotas. A segunda implementação obteve soluções iguais ou melhores que as do *solver* em 23 das 32 instâncias (72%), enquanto a redução média do tempo de CPU foi de 90%. Ainda destacamos, que nos casos em que a heurísticas RF-2S parou em solução de maior custo, elas foram, em média, apenas 1,5% piores.

O tempo elevado da heurística RF-Routes mostra que o subproblema que mistura a atribuição de navios com a seleção de pedidos, embora seja menor em relação




Figura 5.3: Valor objetivo e tempos de CPU relativos da heurística *relax-and-fix*. Resultados do modelo matemático com linha base em 1.0

ao problema original, ainda é consideravelmente difícil de resolver. O tempo adicional necessário para a RF-2S resolver o primeiro estágio compensa pelo fato de os restantes subproblemas serem muito mais fáceis de resolver.

O desempenho superior da solução RF-2S deve-se, provavelmente, ao fato de que a relaxação linear das variáveis de seleção de pedido produzem soluções de excelente qualidade para o problema de alocação de barcos no primeiro estágio. Ao resolver cada rota separadamente, a heurística RF-Routes seleciona as primeiras embarcações de uma forma gulosa e isto influencia as iterações finais. Além disso, como os subproblemas, neste caso, são mais difíceis, o limite de tempo para cada iteração leva a soluções subótimas impactando o resultado final.

5.5.2 Resultados obtidos com a metaheurística ALNS

As metaheurísticas ALNS, diferentemente do *relax-and-fix*, possuem diversos elementos com aleatoriedade. Dessa forma, para o estudo do ALNS elaboramos um projeto diferente de experimentos.

Cada instância foi resolvida pela implementação direta de ALNS e pela implementação ramificada (ALNS-b), tendo sido cada uma dessas testada com o mesmo conjunto de operadores de destruição e reparação. Ademais, cada implementação da metaheurística foi testada com dois métodos de solução inicial distintos - solução gulosa randomizada (Algoritmo 4) e solução aleatória (Algoritmo 5). Por fim, avaliaremos dois tipos de critérios de aceitação de novas soluções: *hill climbing* (hc) e *hill climbing* de aceitação tardia (LAHC). Cada um desses experimentos foi repetido 21 vezes para a produção de estatísticas (tabela no apêndice C).

Como podemos verificar ao analisar os gráficos das Figuras 5.4 e 5.5, a solução gulosa randomizada (Algoritmo 4) apresenta desempenho consideravelmente superior.

Tabela 5.1: Resumo dos resultados obtidos pelo modelo matemático e pela heurística *relax-and-fix*.

Instance	Gurobi				Route Based Relax-and-fix			Two Stage Relax-and-fix		
	Objective	LB	Gap(%)	Cpu(s)	Objective	Gap(%)	Cpu(s)	Objective	Gap(%)	Cpu(s)
G5-C30-V3-P1	290.25	290.25	0.00%	36.67	309.33	6.17%	3.02	309.33	6.17%	2.51
G5-C30-V3-P2	1,144.95	1,144.95	0.00%	343.40	1,201.25	4.69%	7.44	1,149.01	0.35%	8.02
G5-C30-V3-P3	1,898.89	1,898.89	0.00%	337.10	2,032.04	6.55%	4.51	1,910.94	0.63%	7.11
G5-C30-V3-P4	2,488.87	2,472.06	0.70%	1,800	2,925.44	15.48%	45.27	2,488.11	0.62%	209.02
G5-C30-V6-P1	135.98	135.98	0.00%	89.17	135.98	0.00%	8.25	135.98	0.00%	0.72
G5-C30-V6-P2	792.12	776.78	1.90%	1,800	797.28	2.56%	70.54	793.05	2.04%	6.78
G5-C30-V6-P3	1,301.59	1,265.57	2.80%	1,800	1,405.21	9.90%	119.63	1,300.56	2.65%	27.39
G5-C30-V6-P4	2,197.51	2,028.09	7.70%	1,800	2,393.67	15.26%	1,083.83	2,192.61	7.49%	515.75
G10-C60-V8-P4	4,402.37	3,826.43	13.10%	1,800	4,753.52	19.50%	677.33	4,346.32	11.96%	417.43
G10-C60-V14-P4	3,860.18	3,487.32	9.70%	1,800	3,949.9	11.70%	1,504.94	3,712.97	6.07%	514.33
G11-C60-V9-P1	242.98	238.48	1.90%	1,800	242.98	1.83%	114.84	242.98	1.83%	23.27
G11-C60-V9-P2	2,005.2	1,922.1	4.10%	1,800	2,125.34	9.55%	331.88	1,998.14	3.79%	169.13
G11-C60-V15-P1	256.1	251.3	1.90%	1,800	271.04	7.24%	61.78	256.1	1.83%	39.36
G11-C60-V15-P2	1,740.14	1,689.99	2.90%	1,800	1,762.28	4.10%	797.50	1,738.95	2.81%	170.06
G12-C60-V10-P3	3,052.19	2,599.42	14.80%	1,800	3,284.87	20.85%	954.50	2,964.33	12.29%	180.96
G12-C60-V17-P3	2,736.6	2,365.68	13.60%	1,800	2,595.58	8.83%	1,160.74	2,497.44	5.25%	200.63
G15-C90-V13-P2	2,780.76	2,622.82	5.70%	1,800	2,812.99	6.75%	938.91	2,758.52	4.91%	135.26
G15-C90-V22-P2	2,760.31	2,657.67	3.70%	1,800	2,771.0	4.08%	1,063.98	2,748.62	3.29%	138.67
G16-C90-V14-P3	4,964.66	4,224.15	14.90%	1,800	5,541.99	23.77%	945.77	4,841.6	12.74%	196.79
G16-C90-V14-P4	6,447.86	5,541.36	14.10%	1,800	7,123.07	22.20%	1,096.87	6,395.04	13.35%	289.60
G16-C90-V24-P3	4,364.61	3,958.9	9.30%	1,800	4,364.67	9.30%	1,495.75	4,337.07	8.72%	224.51
G16-C90-V24-P4	5,986.9	5,104.09	14.70%	1,800	5,987.62	14.76%	1,576.29	5,799.38	11.99%	345.32
G17-C90-V15-P1	269.85	218.11	19.20%	1,800	356.77	38.80%	463.89	260.44	16.16%	109.52
G17-C90-V25-P1	231.67	214.28	7.50%	1,800	231.67	7.46%	614.07	231.67	7.46%	8.47
G21-C120-V19-P1	591.63	544.59	8.00%	1,800	693.16	21.25%	824.24	597.19	8.60%	94.14
G21-C120-V19-P2	2,981.03	2,579.89	13.50%	1,800	2,827.95	8.78%	1,555.32	2,894.11	10.86%	113.43
G21-C120-V32-P1	700.33	592.07	15.50%	1,800	645.25	8.15%	958.18	643.08	7.84%	96.62
G21-C120-V32-P2	2,612.37	2,415.91	7.50%	1,800	2,616.89	7.69%	1,838.52	2,643.64	8.62%	117.61
G22-C120-V20-P3	6,434.25	5,522.62	14.20%	1,800	6,791.93	18.69%	1,322.75	6,386.81	13.54%	146.96
G22-C120-V34-P3	5,561.53	5,048.72	9.20%	1,800	5,498.08	8.17%	1,856.03	5,583.07	9.57%	217.78
G23-C120-V21-P4	9,012.82	7,334.38	18.60%	1,800	9,506.79	22.85%	1,413.89	9,041.56	18.88%	274.65
G23-C120-V36-P4	8,114.45	6,981.7	14.00%	1,800	7,948.08	12.18%	2,119.95	8,406.21	16.96%	432.77

Comparando as distribuições de probabilidade cumulativas empíricas (Figura 5.4) do valor de GAP em cada instância, vemos com clareza que a heurística gulosa randomizada produz soluções com GAP estatisticamente inferior. Como complemento, na Figura 5.5, é possível observar que a mediana dos valores da função objetivo ficam majoritariamente abaixo do primeiro quartil observado para a solução aleatória, sendo superada em poucas replicações. Em função do melhor desempenho, seguiremos a análise dos resultados do ALNS de forma simplificada considerando apenas a heurística gulosa randomizada para construção da solução inicial.

Observando a Tabela 5.2 podemos notar que na média, o ALNS ramificado (ALNS-b) apresenta soluções melhores do que a implementação pura de ALNS. Em 23 das 32 instâncias tanto nos casos com critério de aceitação hill climbing (HC) quanto nos que utilizaram aceitação tardia (LAHC). A metaheurística ALNS-b deve seu melhor desempenho por conseguir lidar com a estrutura de de solução de forma mais eficiente ao trabalhar com com a alocação de barcos e pedidos separadamente.

5.6 Conclusões

Ao partir para a implementação de métodos heurísticos, buscávamos obter soluções de boa qualidade com tempo computacional reduzido. Neste capítulo, estudamos

Tabela 5.2: Valor esperado da razão entre melhor solução da metaheurística e melhor solução do modelo matemático.

Instance	HC		LAHC		ALNS		ALNS-b	
	ALNS	ALNS-b	ALNS	ALNS-b	HC	LAHC	HC	LAHC
G10-C60-V14-P4	1.146	1.131	1.121	1.135	1.146	1.121	1.131	1.135
G10-C60-V8-P4	1.232	1.227	1.230	1.233	1.232	1.230	1.227	1.233
G11-C60-V15-P1	1.132	1.081	1.118	1.099	1.132	1.118	1.081	1.099
G11-C60-V15-P2	1.188	1.199	1.196	1.199	1.188	1.196	1.199	1.199
G11-C60-V9-P1	2.416	2.438	2.501	2.534	2.416	2.501	2.438	2.534
G11-C60-V9-P2	1.233	1.232	1.237	1.237	1.233	1.237	1.232	1.237
G12-C60-V10-P3	1.336	1.330	1.334	1.330	1.336	1.334	1.330	1.330
G12-C60-V17-P3	1.139	1.113	1.125	1.135	1.139	1.125	1.113	1.135
G15-C90-V13-P2	1.307	1.315	1.307	1.304	1.307	1.307	1.315	1.304
G15-C90-V22-P2	1.148	1.107	1.139	1.115	1.148	1.139	1.107	1.115
G16-C90-V14-P3	1.200	1.200	1.212	1.210	1.200	1.212	1.200	1.210
G16-C90-V14-P4	1.292	1.277	1.289	1.282	1.292	1.289	1.277	1.282
G16-C90-V24-P3	1.130	1.101	1.135	1.129	1.130	1.135	1.101	1.129
G16-C90-V24-P4	1.153	1.140	1.155	1.138	1.153	1.155	1.140	1.138
G17-C90-V15-P1	2.749	2.725	2.739	2.731	2.749	2.739	2.725	2.731
G17-C90-V25-P1	1.571	1.544	1.582	1.540	1.571	1.582	1.544	1.540
G21-C120-V19-P1	2.442	2.393	2.432	2.390	2.442	2.432	2.393	2.390
G21-C120-V19-P2	1.269	1.259	1.257	1.265	1.269	1.257	1.259	1.265
G21-C120-V32-P1	1.227	1.182	1.235	1.215	1.227	1.235	1.182	1.215
G21-C120-V32-P2	1.188	1.175	1.184	1.187	1.188	1.184	1.175	1.187
G22-C120-V20-P3	1.268	1.263	1.281	1.279	1.268	1.281	1.263	1.279
G22-C120-V34-P3	1.186	1.160	1.189	1.168	1.186	1.189	1.160	1.168
G23-C120-V21-P4	1.175	1.169	1.181	1.179	1.175	1.181	1.169	1.179
G23-C120-V36-P4	1.089	1.084	1.095	1.090	1.089	1.095	1.084	1.090
G5-C30-V3-P1	1.862	1.853	1.858	1.854	1.862	1.858	1.853	1.854
G5-C30-V3-P2	1.333	1.333	1.333	1.333	1.333	1.333	1.333	1.333
G5-C30-V3-P3	1.152	1.152	1.153	1.152	1.152	1.153	1.152	1.152
G5-C30-V3-P4	1.321	1.322	1.321	1.322	1.321	1.321	1.322	1.322
G5-C30-V6-P1	1.860	1.855	1.855	1.855	1.860	1.855	1.855	1.855
G5-C30-V6-P2	1.474	1.422	1.479	1.417	1.474	1.479	1.422	1.417
G5-C30-V6-P3	1.271	1.275	1.277	1.275	1.271	1.277	1.275	1.275
G5-C30-V6-P4	1.286	1.288	1.286	1.288	1.286	1.286	1.288	1.288




Figura 5.4: Distribuição empírica de probabilidade acumulada do GAP da solução obtida com as heurísticas aleatória e gulosa randomizada



Figura 5.5: Distribuição do GAP da solução obtida com as heurísticas aleatória e gulosa randomizada

dois tipos de implementação de heurísticas. A primeira com base em heurísticas construtivas híbridas, também conhecidas na literatura como *matheuristics*, do tipo *Relax-and-Fix*, enquanto a segunda baseada na metaheurística *Adaptive Large Neighborhood Search* (ALNS).

Os resultados mostraram que o desempenho da heurística de *Relax-and-Fix* pode ser altamente impactado pela estratégia de decomposição do problema. A nossa implementação, baseada numa decomposição em dois estágios, superou a baseada na rotas, tanto na qualidade da solução como no tempo de processamento. Ao resolver cada rota separadamente, a heurística RF-Routes seleciona as primeiras embarcações de uma forma gulosa e isto influencia as iterações finais. Além disso, como os subproblemas, neste caso, são mais difíceis, o limite de tempo para cada iteração leva a soluções subótimas impactando o resultado final.

Com relação a metaheurística ALNS por meio dos resultados apresentados no capítulo, vimos que apesar de conseguirem gerar soluções viáveis e passear pelo espaço de solução com alguma agilidade, não obtivemos sucesso em superar o desempenho do modelo matemático de forma consistente.

Observamos diferença significativa na qualidade das soluções iniciais utilizando a heurística gulosa randomizada. Por outro lado, os diferentes critérios de aceitação utilizados (*hill climbing* e aceitação tardia) não apresentam diferença de desempenho significativa.

A metaheurística ALNS ramificada (ALNS-b) apresentou desempenho médio superior a implementação simplificada. Por trabalhar apenas com os operadores de destruição e reparação que façam parte da mesma estrutura do problema, a heurística migra para soluções vizinhas de forma mais eficiente evitando reparações inúteis para a destruição realizada.

Capítulo 6

Considerações finais

Esse trabalho nasceu de um projeto de pesquisa desenvolvido em parceria com a Petrobras. A pesquisa possuiu forte ênfase em seu caráter aplicado, mas isso não afastou a produção de publicações acadêmicas em revistas indexadas. Ao longo da pesquisa diferentes aspectos do problema foram abordados e para cada um, uma metodologia de pesquisa mais apropriada foi elaborada.

A hipótese inicial a ser verificada era a viabilidade de se manter a operação de suprimentos com nível de serviço igual ou superior ao praticado, utilizando uma frota de navios multiproduto. Verificada verdadeira, a pergunta seguinte a ser respondida era em quantos navios a frota de embarcações poderia ser reduzida sem comprometimento do nível de serviço.

Para responder a esses questionamentos, utilizamos um modelo de simulação englobando o porto, as unidades marítimas e as embarcações tanque para reabastecimento dos PSVs. A ferramenta reproduz os processos logísticos relacionados aos berços e a movimentação de cargas, levando em consideração diversas variáveis aleatórias, tais como: (i) tempo de movimentação de cargas no berço; (ii) tempo de navegação entre localidades; (iii) tempos de espera e atrasos; (iv) tempo de movimentação de cargas entre PSV e unidade marítima; (v) indisponibilidade de PSVs; e (vi) a produção de uma fila de pedidos de carga geral e diesel para abastecimento.

O gerenciamento dessa fila de pedidos era trabalhado pela empresa com uma regra de negócio do tipo *First In First Out* (FIFO), isto é, os pedidos são agendados para entrega de acordo com sua antiguidade, sujeitando o volume entregue à capacidade das embarcações. Como alternativa para melhor gerir a fila de pedidos, propuzemos um modelo de otimização com o intuito de elevar a quantidade de pedidos entregues no prazo melhor aproveitando a capacidade disponível.

Usando esta metodologia, foi possível replicar as operações atuais, combinando uma política de frota especializada e a estratégia FIFO para a alocação de pedidos. Além disso, propusemos novos cenários considerando a política de frota multiproduto e o uso do modelo de otimização para a seleção de embarcações e para a alocação

de carga no porto.

Podemos afirmar que o transporte de múltiplos tipos de carga no mesmo navio de abastecimento é viável, pois permite reduzir significativamente os custos operacionais e as emissões de gases de efeito estufa, mantendo um alto nível de serviço de entrega de carga. Além disso, a alocação de pedidos por meio de otimização garante ganhos no nível de serviço para frotas de mesmo tamanho.

O modelo de otimização proposto para a escolha de embarcações e da alocação de cargas foi o elemento central das estratégias que apresentaram melhores resultados nos indicadores de desempenho. Esse modelo porém, por estar embarcado num simulador, lida com uma escala de tempo diferente na tomada de decisão. Na sua vivência prática, o tomador de decisão quer planejar essas operações com alguma antecipação, para que não apenas as unidades tenham previsibilidade de suas entregas, mas também os operadores e a tripulação dos navios a tenham. Dessa observação desmembrou-se um ramo dentro da pesquisa da tese para maneiras de incorporar novas decisões ao modelo matemático, de forma que ele seja útil ao planejamento tático. Foram elas: reutilizar a embarcação para viagens futuras e lidar com mais produtos. Essas duas modificações sozinhas aumentaram consideravelmente a complexidade do problema e seu custo computacional, exigindo novos métodos para resolvê-lo.

Quando se trata de problemas reais, uma questão comum quando se publicam resultados e metodologia envolve a utilização informações confidenciais de instituições privadas. Com o objetivo de enfrentar problemas relacionados à confidencialidade dos dados e também para melhorar a reprodutibilidade de nosso trabalho, decidimos criar um conjunto de instâncias que poderiam representar realisticamente o problema comercial original. A partir da análise estatística dos dados obtidos de nosso parceiro de pesquisa, chegamos ao método de geração proposto nesta tese.

Os experimentos realizados com o modelo matemático demonstraram que resolver o problema para instâncias de tamanho considerável tornou-se um desafio do ponto de vista do tempo de processamento. Nesse caso, uma abordagem natural é considerar a utilização de soluções heurísticas para o problema.

Abordagens heurísticas sacrificam a busca pela comprovação de otimalidade da solução em troca de obter boas soluções viáveis mais rapidamente. Nesta tese foram avaliados dois tipos de implementação de heurísticas. A primeira com base em heurísticas construtivas híbridas, também conhecidas na literatura como *matheuristics*, do tipo *Relax-and-Fix*, enquanto a segunda baseada na metaheurística *Adaptive Large Neighborhood Search* (ALNS).

As heurísticas híbridas do tipo *Relax-and-Fix* apresentaram desempenho muito superior ao das metaheurísticas ALNS. Além disso, foram capazes de encontrar soluções melhores do que as soluções benchmark obtidas via programação inteira.

Deve-se destacar a importância da escolha de como particionar o problema ao implementar esse tipo de heurística. A diferença de desempenho tanto em qualidade de solução quanto em tempo de processamento a favor da heurística *Relax-and-Fix* de dois estágios sobre a *Relax-and-Fix* baseada em rotas evidenciam como a estratégia de decomposição pode significar o sucesso da implementação do método.

A mesma conclusão se aplica para o ALNS. Neste trabalho propuzemos uma metaheurística baseada em ALNS chamada ALNS ramificado. Essa implementação tem como base um processo de sorteio do estágio do problema a ser modificado por operadores de destruição e reparação. Com essa abordagem, foi possível garantir consistência no sorteio dos operadores e obter soluções melhores do que numa implementação pura de ALNS. Essas metaheurísticas, porém, não foram superiores a heurística construtiva *Relax-and-Fix*.

6.1 Resultados acadêmicos obtidos relacionados a tese

A pesquisa desenvolvida ao longo da elaboração desta tese produziu resultados acadêmicos que a qualificam como tese de doutorado. Apresentamos aqui uma lista dos resultados mais relevantes entre publicações e prêmios.

Os primeiros resultados obtidos foram submetidos para apresentação em dois congressos: O Simpósio Brasileiro de Pesquisa Operacional - SBPO 2018 e no Rio Oil & Gas 2018 (Apêndices A.1 e A.2).

Um artigo completo envolvendo os resultados apresentados no Capítulo 3 foi submetido e aprovado na revista *Computers & Industrial Engineering* (Apêndice A.3).

Um segundo artigo relacionado ao planejamento de operações com PSV foi submetido na revista *Optimization and Engineering* (Apêndice A.4).

Um terceiro artigo foi submetido na revista *Computers & Industrial Engineering* (Apêndice B.1) e ainda se encontra, no tempo em que esse texto foi finalizado, em processo de revisão por pares. O artigo aborda os resultados obtidos com o modelo matemático expandido e a heurística *relax-and-fix*.

Por último, em 2018, o projeto de pesquisa do qual se originou esta tese foi finalista da Categoria III do Prêmio ANP de Inovação Tecnológica 2018 (ANP, 2018b).

6.2 Trabalhos Futuros

O tema abordado nesta tese é amplo e desafiador. A revisão da literatura mostrou que, embora pesquisas relacionadas a logística de PSVs datem do começo dos anos 2000, este tema é muito abrangente e diversos aspectos ainda foram pouco explorados. Nesta tese, avançamos a pesquisa dando ênfase ao problema de como escolher uma boa alocação de cargas em embarcações. Para dar prosseguimento a linha de pesquisa, enxergamos dois eixos principais.

O primeiro eixo é a elevação da complexidade por meio da inclusão de características da operação que não foram modeladas neste trabalho. Entre elas destacamos: incluir outros produtos na análise como fluidos e cimento; adicionar portos e tornar a escolha de onde realizar o carregamento parte da decisão; incluir sazonalidades meteorológicas que influenciam na velocidade da frota.

O segundo eixo foca no problema de alocação de cargas e em métodos de resolvê-lo. O bom desempenho das heurísticas do tipo *relax-and-fix* se deve a estrutura do problema que favorece sua decomposição em dois estágios. No campo de heurísticas algoritmos híbridos que mesclam o uso de *solvers* de programação inteira com estruturas de heurísticas/metaheurísticas é promissor para problemas com esse tipo de estrutura. Acreditamos que há espaço para a aplicação de outras famílias de heurísticas para a obtenção de soluções de boa qualidade com mais velocidade. No campo de algoritmos exatos, também por conta da estrutura favorável a decomposição, cremos a implementação de decomposição de Benders (BENDERS, 2005) seja caminho promissor para produção de bons resultados experimentais.

Referências Bibliográficas

- AAS, B., GRIBKOVSKAIA, I., HALSKAU, Ø., et al., 2007, “Routing of supply vessels to petroleum installations”, *International Journal of Physical Distribution & Logistics Management*, v. 37, n. 2 (mar), pp. 164–179. doi: 10.1108/09600030710734866. Disponível em: <<https://doi.org/10.1108/09600030710734866>>.
- AAS, B., SR, Ø. H., WALLACE, S. W., 2009, “The role of supply vessels in offshore logistics”, *Maritime Economics & Logistics*, v. 11, n. 3 (aug), pp. 302–325. doi: 10.1057/mel.2009.7. Disponível em: <<https://doi.org/10.1057/mel.2009.7>>.
- ABSI, N., VAN DEN HEUVEL, W., 2019, “Worst case analysis of Relax and Fix heuristics for lot-sizing problems”, *European Journal of Operational Research*, v. 279, n. 2 (dec), pp. 449–458. doi: 10.1016/j.ejor.2019.06.010. Disponível em: <<https://doi.org/10.1016/j.ejor.2019.06.010>>.
- ALBJERK, N., DANIELSEN, T., KREY, S., et al., 2016, “A Vessel Pickup and Delivery Problem from the Disruption Management in Offshore Supply Vessel Operations”. In: *Lecture Notes in Computer Science*, Springer International Publishing, pp. 50–64. doi: 10.1007/978-3-319-44896-1_4.
- ANDERSSON, H., CUESTA, E. F., FAGERHOLT, K., et al., 2015, “Order Management in the Offshore Oil and Gas Industry”. In: *Lecture Notes in Computer Science*, Springer International Publishing, pp. 648–657. doi: 10.1007/978-3-319-24264-4_44. Disponível em: <https://doi.org/10.1007/978-3-319-24264-4_44>.
- ANP, 2018a. “Oil, Natural Gas and Biofuels Statistical Yearbook 2018”. a. Disponível em: <<http://www.anp.gov.br/publicacoes/anuario-estatistico/oil-natural-gas-and-biofuels-statistical-yearbook-2018>>. Acesso em 22 Dezembro 2018.
- ANP, 2018b. “Prêmio ANP de Inovação Tecnológica 2018”. b. Disponível em: <<https://www.gov.br/anp/pt-br/assuntos/pesquisa-desenvolvim>>.

ento-e-inovacao/premio-anp-de-inovacao-tecnologica/edicoes-anteriores/premio-anp-inovacao-tecnologica-2018>. Acesso em 23 Agosto 2022.

ANSELMO, V., MOREIRA, P., LEITE, R., 2017, “Estimation of Diesel Supply Vessels in Offshore Oil & Gas Activities Through Dynamic Simulation”, (10). doi: 10.4043/28014-MS. Disponível em: <<https://doi.org/10.4043/28014-MS>>.

BARRENA, E., CANCA, D., COELHO, L. C., et al., 2014, “Single-line rail rapid transit timetabling under dynamic passenger demand”, *Transportation Research Part B: Methodological*, v. 70, pp. 134–150. doi: 10.1016/j.trb.2014.08.013. Disponível em: <<https://doi.org/10.1016/j.trb.2014.08.013>>.

BENDERS, J. F., 2005, “Partitioning procedures for solving mixed-variables programming problems”, *Computational Management Science*, v. 2, n. 1 (jan), pp. 3–19. doi: 10.1007/s10287-004-0020-y. Disponível em: <<https://doi.org/10.1007/s10287-004-0020-y>>.

BORTHEN, T., LOENNECHEN, H., WANG, X., et al., 2018, “A genetic search-based heuristic for a fleet size and periodic routing problem with application to offshore supply planning”, *EURO Journal on Transportation and Logistics*, v. 7, n. 2 (jun), pp. 121–150. doi: 10.1007/s13676-017-0111-x. Disponível em: <<https://doi.org/10.1007/s13676-017-0111-x>>.

BORTHEN, T., LOENNECHEN, H., FAGERHOLT, K., et al., 2019, “Bi-objective offshore supply vessel planning with costs and persistence objectives”, *Computers & Operations Research*, v. 111 (nov), pp. 285–296. doi: 10.1016/j.cor.2019.06.014. Disponível em: <<https://doi.org/10.1016/j.cor.2019.06.014>>.

BP, 2018, *Statistical Review of World Energy 2018*. Relatório técnico. Disponível em: <<https://www.bp.com/content/dam/bp/en/corporate/pdf/energy-economics/statistical-review/bp-stats-review-2018-full-report.pdf>>.

BRAHIMI, N., AOUAM, T., 2015, “Multi-item production routing problem with backordering: a MILP approach”, *International Journal of Production Research*, v. 54, n. 4 (jun), pp. 1076–1093. doi: 10.1080/00207543.2015.1047971. Disponível em: <<https://doi.org/10.1080/00207543.2015.1047971>>.

- BRANDIMARTE, P., 2006, “Multi-item capacitated lot-sizing with demand uncertainty”, *International Journal of Production Research*, v. 44, n. 15 (aug), pp. 2997–3022. doi: 10.1080/00207540500435116. Disponível em: <<https://doi.org/10.1080/00207540500435116>>.
- BULMER, M., 1979, “Principles of Statistics”. 2 ed., Dover Publications. ISBN: 9780486637600.
- CANCA, D., DE-LOS-SANTOS, A., LAPORTE, G., et al., 2017, “An adaptive neighborhood search metaheuristic for the integrated railway rapid transit network design and line planning problem”, *Computers & Operations Research*, v. 78, pp. 1–14. doi: 10.1016/j.cor.2016.08.008. Disponível em: <<https://doi.org/10.1016%2Fj.cor.2016.08.008>>.
- CANCA, D., DE-LOS-SANTOS, A., LAPORTE, G., et al., 2019, “Integrated Railway Rapid Transit Network Design and Line Planning problem with maximum profit”, *Transportation Research Part E: Logistics and Transportation Review*, v. 127, pp. 1–30. doi: 10.1016/j.tre.2019.04.007. Disponível em: <<https://doi.org/10.1016%2Fj.tre.2019.04.007>>.
- CHEN, L., HÀ, M. H., LANGEVIN, A., et al., 2014, “Optimizing road network daily maintenance operations with stochastic service and travel times”, *Transportation Research Part E: Logistics and Transportation Review*, v. 64, pp. 88–102. doi: 10.1016/j.tre.2014.02.002. Disponível em: <<https://doi.org/10.1016%2Fj.tre.2014.02.002>>.
- CHRISTIANSEN, M., FAGERHOLT, K., 2002, “Robust ship scheduling with multiple time windows”, *Naval Research Logistics*, v. 49, n. 6 (aug), pp. 611–625. doi: 10.1002/nav.10033. Disponível em: <<https://doi.org/10.1002/nav.10033>>.
- CONTARDO, C., HEMMELMAYR, V., CRAINIC, T. G., 2012, “Lower and upper bounds for the two-echelon capacitated location-routing problem”, *Computers and Operations Research*, v. 39, n. 12, pp. 3185–3199. ISSN: 03050548. doi: 10.1016/j.cor.2012.04.003. Disponível em: <<https://www2.scopus.com/inward/record.uri?eid=2-s2.0-84862977590&doi=10.1016%2Fj.cor.2012.04.003&partnerID=40&md5=17bdbdad60bc2668bc2476a22f464c0e>>.
- CORDEAU, J.-F., LAPORTE, G., MOCCIA, L., et al., 2011, “Optimizing yard assignment in an automotive transshipment terminal”, *European Journal of Operational Research*, v. 215, n. 1, pp. 149–160. doi: 10.1016/j.ejor.2

011.06.008. Disponível em: <<https://doi.org/10.1016%2Fj.ejor.2011.06.008>>.

CUESTA, E. F., ANDERSSON, H., FAGERHOLT, K., et al., 2017a, “Vessel routing with pickups and deliveries: An application to the supply of offshore oil platforms”, *Computers & Operations Research*, v. 79 (mar), pp. 140–147. doi: 10.1016/j.cor.2016.10.014. Disponível em: <<https://doi.org/10.1016/j.cor.2016.10.014>>.

CUESTA, E. F., ANDERSSON, H., FAGERHOLT, K., et al., 2017b, “Vessel routing with pickups and deliveries: An application to the supply of offshore oil platforms”, *Computers & Operations Research*, v. 79, pp. 140–147. doi: 10.1016/j.cor.2016.10.014. Disponível em: <<https://doi.org/10.1016%2Fj.cor.2016.10.014>>.

DALEEL OIL & GAS SUPPLY CHAIN PORTAL, 2021. “Platform Supply Vessel (PSV)”. Disponível em: <<https://www.scmdaleel.com/category/platform-supply-vessel-psv/174>>.

DE ARAUJO, S. A., ARENALES, M. N., CLARK, A. R., 2007, “Joint rolling-horizon scheduling of materials processing and lot-sizing with sequence-dependent setups”, *Journal of Heuristics*, v. 13, n. 4 (apr), pp. 337–358. doi: 10.1007/s10732-007-9011-9. Disponível em: <<https://doi.org/10.1007/s10732-007-9011-9>>.

DE BITTENCOURT, G. C., SEIMETZ CHAGAS, R. D., SILVA, V. A., et al., 2021, “A solution framework for the integrated problem of cargo assignment, fleet sizing, and delivery planning in offshore logistics”, *Computers & Industrial Engineering*, p. 107653. ISSN: 0360-8352. doi: 10.1016/j.cie.2021.107653. Disponível em: <<https://doi.org/10.1016/j.cie.2021.107653>>.

EIA, 2016. “Offshore production nearly 30% of global crude oil output in 2015”. Disponível em: <<https://www.eia.gov/todayinenergy/detail.php?id=28492>>. Accessed on 22 December 2018.

FAGERHOLT, K., 1999, “Optimal fleet design in a ship routing problem”, *International Transactions in Operational Research*, v. 6, n. 5 (sep), pp. 453–464. doi: 10.1111/j.1475-3995.1999.tb00167.x. Disponível em: <<https://doi.org/10.1111/j.1475-3995.1999.tb00167.x>>.

FAGERHOLT, K., LINDSTAD, H., 2000, “Optimal policies for maintaining a supply service in the Norwegian Sea”, *Omega*, v. 28, n. 3 (jun), pp. 269–

275. doi: 10.1016/s0305-0483(99)00054-7. Disponível em: <[https://doi.org/10.1016/s0305-0483\(99\)00054-7](https://doi.org/10.1016/s0305-0483(99)00054-7)>.

FIOROTTO, D. J., DEL CARMEN HUACCHA NEYRA, J., DE ARAUJO, S. A., 2019, “Impact analysis of setup carryover and crossover on lot sizing problems”, *International Journal of Production Research*, v. 58, n. 20 (oct), pp. 6350–6369. doi: <https://doi.org/10.1080/00207543.2019.1680892>. Disponível em: <<https://doi.org/10.1080/00207543.2019.1680892>>.

FISHER, M. L., JAIKUMAR, R., WASSENHOVE, L. N. V., 1986, “A Multiplier Adjustment Method for the Generalized Assignment Problem”, *Management Science*, v. 32, n. 9 (set.), pp. 1095–1103. doi: 10.1287/mnsc.32.9.1095. Disponível em: <<https://doi.org/10.1287/mnsc.32.9.1095>>.

GHAREHGOZLI, A. H., LAPORTE, G., YU, Y., et al., 2015, “Scheduling Twin Yard Cranes in a Container Block”, *Transportation Science*, v. 49, n. 3, pp. 686–705. doi: 10.1287/trsc.2014.0533. Disponível em: <<https://doi.org/10.1287/trsc.2014.0533>>.

GHILAS, V., DEMIR, E., WOENSEL, T. V., 2016, “An adaptive large neighborhood search heuristic for the Pickup and Delivery Problem with Time Windows and Scheduled Lines”, *Computers & Operations Research*, v. 72, pp. 12–30. doi: 10.1016/j.cor.2016.01.018. Disponível em: <<https://doi.org/10.1016/j.cor.2016.01.018>>.

GHONIEM, A., SCHERRER, C. R., SOLAK, S., 2013, “A specialized column generation approach for a vehicle routing problem with demand allocation”, *Journal of the Operational Research Society*, v. 64, n. 1 (jan), pp. 114–124. doi: 10.1057/jors.2012.32. Disponível em: <<https://doi.org/10.1057/jors.2012.32>>.

GRIBKOVSKAIA, I., LAPORTE, G., SHLOPAK, A., 2008, “A tabu search heuristic for a routing problem arising in servicing of offshore oil and gas platforms”, *Journal of the Operational Research Society*, v. 59, n. 11 (nov), pp. 1449–1459. doi: 10.1057/palgrave.jors.2602469.

GRIMAULT, A., BOSTEL, N., LEHUÉDÉ, F., 2017, “An adaptive large neighborhood search for the full truckload pickup and delivery problem with resource synchronization”, *Computers & Operations Research*, v. 88, pp. 1–14. doi: 10.1016/j.cor.2017.06.012. Disponível em: <<https://doi.org/10.1016/j.cor.2017.06.012>>.

- HALVORSEN-WEARE, E. E., FAGERHOLT, K., 2016, “Optimization in offshore supply vessel planning”, *Optimization and Engineering*, v. 18, n. 1 (mar), pp. 317–341. doi: 10.1007/s11081-016-9315-4. Disponível em: <<https://doi.org/10.1007/s11081-016-9315-4>>.
- HALVORSEN-WEARE, E. E., FAGERHOLT, K., 2011, “Robust Supply Vessel Planning”. In: *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, pp. 559–573. doi: 10.1007/978-3-642-21527-8_62. Disponível em: <https://doi.org/10.1007/978-3-642-21527-8_62>.
- HALVORSEN-WEARE, E. E., FAGERHOLT, K., NONÁS, L. M., et al., 2012, “Optimal fleet composition and periodic routing of offshore supply vessels”, *European Journal of Operational Research*, v. 223, n. 2 (dec), pp. 508–517. doi: 10.1016/j.ejor.2012.06.017. Disponível em: <<https://doi.org/10.1016/j.ejor.2012.06.017>>.
- HASANI, A., KHOSROJERDI, A., 2016, “Robust global supply chain network design under disruption and uncertainty considering resilience strategies: A parallel memetic algorithm for a real-life case study”, *Transportation Research Part E: Logistics and Transportation Review*, v. 87, pp. 20–52. doi: 10.1016/j.tre.2015.12.009. Disponível em: <<https://doi.org/10.1016%2Fj.tre.2015.12.009>>.
- HEMMATI, A., HVATTUM, L. M., 2016, “Evaluating the importance of randomization in adaptive large neighborhood search”, *International Transactions in Operational Research*, v. 24, n. 5, pp. 929–942. doi: 10.1111/itor.12273. Disponível em: <<https://doi.org/10.1111%2Fitor.12273>>.
- IACHAN, R., 2009, “A Brazilian experience: 40 years using operations research at Petrobras”, *International Transactions in Operational Research*, v. 16, n. 5 (sep), pp. 585–593. doi: 10.1111/j.1475-3995.2009.00717.x. Disponível em: <<https://doi.org/10.1111/j.1475-3995.2009.00717.x>>.
- IRIS, [PLEASEINSERT“PRERENDERUNICODE–.”INTOPREAMBLE], PACINO, D., ROPKE, S., 2017, “Improved formulations and an Adaptive Large Neighborhood Search heuristic for the integrated berth allocation and quay crane assignment problem”, *Transportation Research Part E: Logistics and Transportation Review*, v. 105, pp. 123–147. doi: 10.1016/j.tre.2017.06.013. Disponível em: <<https://doi.org/10.1016%2Fj.tre.2017.06.013>>.
- KAISER, M. J., 2010, “An integrated systems framework for service vessel forecasting in the Gulf of Mexico”, *Energy*, v. 35, n. 7 (jul), pp. 2777–

2795. doi: 10.1016/j.energy.2010.02.028. Disponível em: <<https://doi.org/10.1016/j.energy.2010.02.028>>.

KAISER, M. J., 2016, “Service vessel activity in the U.S. Gulf of Mexico in support of the oil and gas industry using AIS data, 2009-2010”, *Marine Policy*, v. 63, pp. 61–80. ISSN: 0308597X. doi: 10.1016/j.marpol.2015.09.032. Disponível em: <<http://dx.doi.org/10.1016/j.marpol.2015.09.032>>.

KIEFER, A., HARTL, R. F., SCHNELL, A., 2016, “Adaptive large neighborhood search for the curriculum-based course timetabling problem”, *Annals of Operations Research*, v. 252, n. 2, pp. 255–282. doi: 10.1007/s10479-016-2151-2. Disponível em: <<https://doi.org/10.1007/s10479-016-2151-2>>.

KISIALIOU, Y., GRIBKOVSKAIA, I., LAPORTE, G., 2018a, “The periodic supply vessel planning problem with flexible departure times and coupled vessels”, *Computers & Operations Research*, v. 94 (jun), pp. 52–64. doi: 10.1016/j.cor.2018.02.008. Disponível em: <<https://doi.org/10.1016/j.cor.2018.02.008>>.

KISIALIOU, Y., GRIBKOVSKAIA, I., LAPORTE, G., 2018b, “Robust supply vessel routing and scheduling”, *Transportation Research Part C: Emerging Technologies*, v. 90 (may), pp. 366–378. doi: 10.1016/j.trc.2018.03.012. Disponível em: <<https://doi.org/10.1016/j.trc.2018.03.012>>.

KISIALIOU, Y., GRIBKOVSKAIA, I., LAPORTE, G., 2019, “Supply vessel routing and scheduling under uncertain demand”, *Transportation Research Part C: Emerging Technologies*, v. 104 (jul), pp. 305–316. doi: 10.1016/j.trc.2019.04.011. Disponível em: <<https://doi.org/10.1016/j.trc.2019.04.011>>.

KRISTIANSEN, S., STIDSEN, T. R., 2014, “Elective course student sectioning at Danish high schools”, *Annals of Operations Research*, v. 239, n. 1, pp. 99–117. doi: 10.1007/s10479-014-1593-7. Disponível em: <<https://doi.org/10.1007/s10479-014-1593-7>>.

KRISTIANSEN, S., SØRENSEN, M., HEROLD, M. B., et al., 2013, “The consultation timetabling problem at Danish high schools”, *Journal of Heuristics*, v. 19, n. 3, pp. 465–495. doi: 10.1007/s10732-013-9219-9. Disponível em: <<https://doi.org/10.1007/s10732-013-9219-9>>.

- LAPORTE, G., MUSMANNO, R., VOCATURO, F., 2010, “An adaptive large neighbourhood search heuristic for the capacitated arc-routing problem with stochastic demands”, *Transportation Science*, v. 44, n. 1, pp. 125–135. ISSN: 00411655. doi: 10.1287/trsc.1090.0290. Disponível em: <<https://doi.org/10.1287/trsc.1090.0290>>.
- LEE, Y. C. E., CHAN, C. K., LANGEVIN, A., et al., 2016, “Integrated inventory-transportation model by synchronizing delivery and production cycles”, *Transportation Research Part E: Logistics and Transportation Review*, v. 91, pp. 68–89. doi: 10.1016/j.tre.2016.03.017. Disponível em: <<https://doi.org/10.1016/j.tre.2016.03.017>>.
- LEITE, R. P., 2012, *Maritime transport of deck cargo to Petrobras fields in Campos Basin: an empirical analysis, identification and quantification of improvement points*. Dissertação de mestrado, PUC-Rio, Rio de Janeiro.
- LI, D., ZHANG, T., DONG, X., et al., 2019, “Trade-off between efficiency and fairness in timetabling on a single urban rail transit line under time-dependent demand condition”, *Transportmetrica B: Transport Dynamics*, v. 7, n. 1, pp. 1203–1231. doi: 10.1080/21680566.2019.1589598. Disponível em: <<https://doi.org/10.1080/21680566.2019.1589598>>.
- MASSON, R., LEHUÉDÉ, F., PÉTON, O., 2013, “An Adaptive Large Neighborhood Search for the Pickup and Delivery Problem with Transfers”, *Transportation Science*, v. 47, n. 3, pp. 344–355. doi: 10.1287/trsc.1120.0432. Disponível em: <<https://doi.org/10.1287/trsc.1120.0432>>.
- MASSON, R., TRENTINI, A., LEHUÉDÉ, F., et al., 2015, “Optimization of a city logistics transportation system with mixed passengers and goods”, *EURO Journal on Transportation and Logistics*, v. 6, n. 1, pp. 81–109. doi: 10.1007/s13676-015-0085-5. Disponível em: <<https://doi.org/10.1007/s13676-015-0085-5>>.
- MASSON, R., LAHRICHI, N., ROUSSEAU, L.-M., 2016, “A two-stage solution method for the annual dairy transportation problem”, *European Journal of Operational Research*, v. 251, n. 1, pp. 36–43. doi: 10.1016/j.ejor.2015.10.058. Disponível em: <<https://doi.org/10.1016/j.ejor.2015.10.058>>.
- MAURI, G. R., RIBEIRO, G. M., LORENA, L. A. N., et al., 2016, “An adaptive large neighborhood search for the discrete and continuous Berth allocation problem”, *Computers & Operations Research*, v. 70, pp. 140–154. doi:

10.1016/j.cor.2016.01.002. Disponível em: <<https://doi.org/10.1016/j.cor.2016.01.002>>.

MENDES, A. P. D. A., TEIXEIRA, C. A. N., ROCIO, M. A. R., et al., 2017, “Panoramas setoriais 2030: petróleo e gás”. In: *Panoramas setoriais 2030: desafios e oportunidades para o Brasil*, Banco Nacional de Desenvolvimento Econômico e Social, pp. 93–105, Rio de Janeiro.

MOHRI, S. S., KARIMI, H., KORDANI, A. A., et al., 2018, “Airline hub-and-spoke network design based on airport capacity envelope curve: A practical view”, *Computers & Industrial Engineering*, v. 125, pp. 375–393. doi: 10.1016/j.cie.2018.09.010. Disponível em: <<https://doi.org/10.1016/j.cie.2018.09.010>>.

MORENO, A., ALEM, D., FERREIRA, D., 2016, “Heuristic approaches for the multiperiod location-transportation problem with reuse of vehicles in emergency logistics”, *Computers & Operations Research*, v. 69 (may), pp. 79–96. doi: 10.1016/j.cor.2015.12.002. Disponível em: <<https://doi.org/10.1016/j.cor.2015.12.002>>.

MULLER, L. F., SPOORENDONK, S., PISINGER, D., 2012, “A hybrid adaptive large neighborhood search heuristic for lot-sizing with setup times”, *European Journal of Operational Research*, v. 218, n. 3, pp. 614–623. doi: 10.1016/j.ejor.2011.11.036. Disponível em: <<https://doi.org/10.1016/j.ejor.2011.11.036>>.

NORLUND, E. K., GRIBKOVSKAIA, I., 2013, “Reducing emissions through speed optimization in supply vessel operations”, *Transportation Research Part D: Transport and Environment*, v. 23 (aug), pp. 105–113. doi: 10.1016/j.trd.2013.04.007. Disponível em: <<https://doi.org/10.1016/j.trd.2013.04.007>>.

NORLUND, E. K., GRIBKOVSKAIA, I., LAPORTE, G., 2015, “Supply vessel planning under cost, environment and robustness considerations”, *Omega*, v. 57 (dec), pp. 271–281. doi: 10.1016/j.omega.2015.05.006. Disponível em: <<https://doi.org/10.1016/j.omega.2015.05.006>>.

OLIVEIRA, B. B., CARRAVILLA, M. A., OLIVEIRA, J. F., et al., 2014, “A relax-and-fix-based algorithm for the vehicle-reservation assignment problem in a car rental company”, *European Journal of Operational Research*, v. 237, n. 2 (sep), pp. 729–737. doi: 10.1016/j.ejor.2014.02.018. Disponível em: <<https://doi.org/10.1016/j.ejor.2014.02.018>>.

- PISINGER, D., ROPKE, S., 2007, “A general heuristic for vehicle routing problems”, *Computers & Operations Research*, v. 34, n. 8, pp. 2403–2435. doi: 10.1016/j.cor.2005.09.012. Disponível em: <<https://doi.org/10.1016%2Fj.cor.2005.09.012>>.
- POCHET, Y., WOLSEY, L. A., 2006, “Mixed Integer Programming Algorithms”. In: *Production Planning by Mixed Integer Programming*, Springer New York, pp. 77–113, New York, NY. Disponível em: <https://doi.org/10.1007/0-387-33477-7_4>.
- QU, Y., BARD, J. F., 2012, “A GRASP with adaptive large neighborhood search for pickup and delivery problems with transshipment”, *Computers & Operations Research*, v. 39, n. 10, pp. 2439–2456. doi: 10.1016/j.cor.2011.11.016. Disponível em: <<https://doi.org/10.1016%2Fj.cor.2011.11.016>>.
- RIBEIRO, G. M., LAPORTE, G., 2012, “An adaptive large neighborhood search heuristic for the cumulative capacitated vehicle routing problem”, *Computers & Operations Research*, v. 39, n. 3, pp. 728–735. doi: 10.1016/j.cor.2011.05.005. Disponível em: <<https://doi.org/10.1016%2Fj.cor.2011.05.005>>.
- RIBEIRO, G. M., DESAULNIERS, G., DESROSIERS, J., et al., 2014, “Efficient heuristics for the workover rig routing problem with a heterogeneous fleet and a finite horizon”, *Journal of Heuristics*, v. 20, n. 6, pp. 677–708. doi: 10.1007/s10732-014-9262-1. Disponível em: <<https://doi.org/10.1007%2Fs10732-014-9262-1>>.
- RIBEIRO, G. M., MAURI, G. R., BELUCO, S. D. C., et al., 2016, “Berth allocation in an ore terminal with demurrage, despatch and maintenance”, *Computers & Industrial Engineering*, v. 96, pp. 8–15. doi: 10.1016/j.cie.2016.03.005. Disponível em: <<https://doi.org/10.1016%2Fj.cie.2016.03.005>>.
- RODRIGUES, V., MORABITO, R., YAMASHITA, D., et al., 2016, “Ship Routing with Pickup and Delivery for a Maritime Oil Transportation System: MIP Model and Heuristics”, *Systems*, v. 4, n. 3 (sep), pp. 31. doi: 10.3390/systems4030031.
- ROPKE, S., PISINGER, D., 2006a, “An Adaptive Large Neighborhood Search Heuristic for the Pickup and Delivery Problem with Time Windows”, *Transportation Science*, v. 40, n. 4, pp. 455–472. doi: 10.1287/trsc.1050.0135. Disponível em: <<https://doi.org/10.1287%2Ftrsc.1050.0135>>.

- ROPKE, S., PISINGER, D., 2006b, “A unified heuristic for a large class of Vehicle Routing Problems with Backhauls”, *European Journal of Operational Research*, v. 171, n. 3, pp. 750–775. doi: 10.1016/j.ejor.2004.09.004. Disponível em: <<https://doi.org/10.1016%2Fj.ejor.2004.09.004>>.
- SANTINI, A., ROPKE, S., HVATTUM, L. M., 2018, “A comparison of acceptance criteria for the adaptive large neighbourhood search metaheuristic”, *Journal of Heuristics*, v. 24, n. 5, pp. 783–815. doi: 10.1007/s10732-018-9377-x. Disponível em: <<https://doi.org/10.1007%2Fs10732-018-9377-x>>.
- SARGENT, R., 2010, “Verification and validation of simulation models”. In: *2010 Winter Simulation Conference*, pp. 166–183.
- SCHIFFER, M., WALTHER, G., 2018, “Strategic planning of electric logistics fleet networks: A robust location-routing approach”, *Omega (United Kingdom)*, v. 80, pp. 31–42. ISSN: 03050483. doi: 10.1016/j.omega.2017.09.003. Disponível em: <<https://www2.scopus.com/inward/record.uri?eid=2-s2.0-85030538996&doi=10.1016%2fj.omega.2017.09.003&partnerID=40&md5=69f4cf0208ce156407e5d97324b8bb5b>>.
- SEIMETZ CHAGAS, R. D., FERREIRA FILHO, V. J. M., 2021. “Instances for Multi-Commodity Supply Vessel Planning Problem With Order Selection and Time Window Decisions”. Disponível em: <<https://github.com/chagasrennan/SVPP>>.
- SEIMETZ CHAGAS, R. D., DE OLIVEIRA SOARES, J. B. C., LONGHI, R. P., et al., 2022, “A solution framework for the integrated periodic supply vessel planning and port scheduling in oil and gas supply logistics”, *Optimization and Engineering*, (ago.). doi: 10.1007/s11081-022-09742-3. Disponível em: <<https://doi.org/10.1007/s11081-022-09742-3>>.
- SHAW, P., 1998, “Using Constraint Programming and Local Search Methods to Solve Vehicle Routing Problems”. In: *Principles and Practice of Constraint Programming — CP98*, Springer Berlin Heidelberg, pp. 417–431. doi: 10.1007/3-540-49481-2_30.
- SHYSHOU, A., GRIBKOVSKAIA, I., LAPORTE, G., et al., 2012, “A Large Neighbourhood Search Heuristic for a Periodic Supply Vessel Planning Problem Arising in Offshore Oil and Gas Operations”, *INFOR: Information Systems and Operational Research*, v. 50, n. 4 (nov), pp. 195–204. doi: 10.3138/infor.50.4.195. Disponível em: <<https://doi.org/10.3138/infor.50.4.195>>.

- SMET, N. D., MINNER, S., AGHEZZAF, E.-H., et al., 2020, “A linearisation approach to the stochastic dynamic capacitated lot sizing problem with sequence-dependent changeovers”, *International Journal of Production Research*, v. 58, n. 16 (mar), pp. 4980–5005. doi: 10.1080/00207543.2020.1736722. Disponível em: <<https://doi.org/10.1080/00207543.2020.1736722>>.
- SOROUGH, H. M., AL-YAKOOB, S. M., 2018, “A maritime scheduling transportation-inventory problem with normally distributed demands and fully loaded/unloaded vessels”, *Applied Mathematical Modelling*, v. 53, pp. 540–566. ISSN: 0307904X. doi: 10.1016/j.apm.2017.08.015. Disponível em: <<https://doi.org/10.1016/j.apm.2017.08.015>>.
- STEADIESEIFI, M., DELLAERT, N. P., NUIJTEN, W., et al., 2017, “A metaheuristic for the multimodal network flow problem with product quality preservation and empty repositioning”, *Transportation Research Part B: Methodological*, v. 106, pp. 321–344. doi: 10.1016/j.trb.2017.07.007. Disponível em: <<https://doi.org/10.1016%2Fj.trb.2017.07.007>>.
- SÁ, E. M. D., CONTRERAS, I., CORDEAU, J.-F., 2015, “Exact and heuristic algorithms for the design of hub networks with multiple lines”, *European Journal of Operational Research*, v. 246, n. 1, pp. 186–198. doi: 10.1016/j.ejor.2015.04.017. Disponível em: <<https://doi.org/10.1016%2Fj.ejor.2015.04.017>>.
- TOSO, E. A., MORABITO, R., CLARK, A. R., 2009, “Lot sizing and sequencing optimisation at an animal-feed plant”, *Computers & Industrial Engineering*, v. 57, n. 3 (oct), pp. 813–821. doi: 10.1016/j.cie.2009.02.011. Disponível em: <<https://doi.org/10.1016/j.cie.2009.02.011>>.
- U.S. ENERGY INFORMATION ADMINISTRATION, 2020. “New York Harbor No. 2 Heating Oil Spot Price FOB”. Disponível em: <https://www.eia.gov/dnav/pet/hist/eer_epd2f_pf4_y35ny_dpgD.htm>.
- VIANNA, I. G. P., 2019, *Análise da alocação de embarcações de apoio offshore com o uso de heurísticas e simulação de eventos discretos*. Dissertação, Universidade Federal do Rio de Janeiro, Rio de Janeiro, mar. Disponível em: <<http://hdl.handle.net/11422/13263>>.
- WANG, F. K., 2001, “Confidence interval for the mean of non normal data”, *Quality and Reliability Engineering International*, v. 17, pp. 257–267. ISSN: 1099-1638. Disponível em: <<https://doi.org/10.1002/qre.400>>.

- WEI, M., QI, M., WU, T., et al., 2019, “Distance and matching-induced search algorithm for the multi-level lot-sizing problem with substitutable bill of materials”, *European Journal of Operational Research*, v. 277, n. 2 (sep), pp. 521–541. doi: 10.1016/j.ejor.2019.03.001. Disponível em: <<https://doi.org/10.1016/j.ejor.2019.03.001>>.
- WOLSEY, L. A., 1998, *Integer Programming*. New York, John Wiley & Sons. ISBN: 0471283665.
- ZIEBUHR, M., KOPFER, H., 2014, “The integrated operational transportation planning problem with compulsory requests”, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 8760. ISSN: 03029743. Disponível em: <<https://www2.scopus.com/inward/record.uri?eid=2-s2.0-84921919546&partnerID=40&md5=9d0ff0aed84809a63aec94c75bb1e474>>.
- ZIEBUHR, M., KOPFER, H., 2016, “Solving an integrated operational transportation planning problem with forwarding limitations”, *Transportation Research Part E: Logistics and Transportation Review*, v. 87, pp. 149–166. doi: 10.1016/j.tre.2016.01.006. Disponível em: <<https://doi.org/10.1016%2Fj.tre.2016.01.006>>.
- ZIMBERG, B., TESTURI, C. E., FERRARI, G., 2019, “Stochastic modeling of fuel procurement for electricity generation with contractual terms and logistics constraints”, *Computers & Chemical Engineering*, v. 123 (apr), pp. 49–63. doi: 10.1016/j.compchemeng.2018.12.021. Disponível em: <<https://doi.org/10.1016/j.compchemeng.2018.12.021>>.

Apêndice A

Trabalhos publicados

A.1 L SBPO - 2018

Programação de Cargas em Barcos de Suprimento de Unidades Marítimas

Rennan Danilo Seimetz Chagas[†], Victor Anselmo Silva[‡], Gustavo Cunha de Bittencourt[†],
Rafael Pedro Longhi[†], Igor Girão Peres Vianna[†], Paulo Cesar Ribas[‡], Virgílio José Martins
Ferreira Filho[†]

[†] Programa de Engenharia de Produção/COPPE/UFRJ

[‡] Petróleo Brasileiro S.A – CENPES

Centro de Tecnologia, Bloco F, Cidade Universitária, Rio de Janeiro-RJ

CENPES, Cidade Universitária, Rio de Janeiro-RJ

chagasrennan@gmail.com, victor.anselmo@petrobras.com.br,

gustavo@gustavo.im, rafaelplonghi@poli.ufrj.br,

igor_gpv@poli.ufrj.br, paulo.ribas@petrobras.com.br,

virgilio@ufrj.br

RESUMO

As atividades de exploração e produção de óleo e gás (E&P) *offshore*, têm imposto grandes desafios à área de planejamento e operação de recursos e infraestrutura logísticos. O dimensionamento e a utilização adequados das embarcações supridoras são fundamentais para manutenção de uma operação eficiente e com custo aceitável, dado que a quantidade de cargas movimentada é vultosa. Neste trabalho é apresentado um modelo matemático de otimização inteira mista que realiza a programação de cargas em barcos de suprimento, visando maximização do nível de serviço, traduzido pelo percentual de entrega de cargas às unidades marítimas dentro do prazo. Este modelo é inserido em um simulador que replica realisticamente as condições operacionais. Apesar do acoplamento de um modelo de otimização a um modelo de simulação gerar um tempo significativo de execução, o ganho em qualidade da solução é significativo, gerando uma melhoria média de 2,5% no nível de serviço no cenário testado.

PALAVRAS CHAVE. Logística *offshore*, simulação, programação inteira mista.

ABSTRACT

Offshore oil and gas exploration and production (E&P) activities have imposed major challenges to planning and operation of resources and logistics infrastructure. Proper dimensioning and use of supply vessels are essential tasks to hold an efficient and cost-effective operation, since the amount of cargo handled is substantial. In this work a mathematical model of mixed integer optimization is presented, which performs cargo scheduling from a fleet of supply vessels, in order to maximize the service level, defined as the percentage of cargo delivered on time to maritime units. This model runs as an called-on-demand external subroutine of a simulator that realistically represents the operating conditions. In spite of the fact the coupling an optimization model in a simulation process generates significant increase in execution time, the quality of the solution has significantly improved, generating an average gain of 2.5% in the service level for the studied scenario.

KEYWORDS. Offshore logistics, simulation, mixed integer programming.

A.2 Rio Oil & Gas - 2018



IBP1883_18
**DECISION SUPPORT TOOL APPLIED
TO SUPPLY VESSEL SCHEDULING IN
OFFSHORE LOGISTICS**

Victor A. Silva¹, Gustavo C. Bittencourt², Igor G.P. Vianna³, Rennan S. Chagas⁴, Rafael P. Longhi⁵, Paulo C. Ribas⁶, Virgílio J.M. Ferreira Filho⁷

Copyright 2018, Brazilian Petroleum, Gas and Biofuels Institute - IBP

This Technical Paper was prepared for presentation at the *Rio Oil & Gas Expo and Conference 2018*, held between 24 and 27 of September, in Rio de Janeiro. This Technical Paper was selected for presentation by the Technical Committee of the event according to the information contained in the final paper submitted by the author(s). The organizers are not supposed to translate or correct the submitted papers. The material as it is presented, does not necessarily represent Brazilian Petroleum, Gas and Biofuels Institute's opinion, or that of its Members or Representatives. Authors consent to the publication of this Technical Paper in the *Rio Oil & Gas Expo and Conference 2018 Proceedings*.

Abstract

Offshore oil and gas exploration and production (E&P) activities have imposed major challenges to planning and operation of resources and logistics infrastructure. Proper dimensioning and use of supply vessels are essential tasks to hold an efficient and cost-effective operation, since the amount of cargo handled is substantial. We present a decision support tool for vessel schedule decisions in offshore logistics, comprehending integrated discrete simulation and an optimization models. We built a simulator that realistically represents the operating conditions, modeling the port, the maritime units and the tank vessels where occurs the PSVs refueling. In optimizer, we solve the cargo-scheduling problem necessary for simulation, using commercial solver and general purpose language Python. Communication between models occurs in an architecture client/server, using sockets. On experiments, we test functionality of this tool, obtaining good results. In particular, those conducted to assess the use of multiple loads on a supply vessel are feasible and can generate a more cost-efficient operation while maintaining the equivalent level of service. Finally, as general conclusion, we expect that this tool can be very useful to help decisions, offering a great flexibility for any scenario.

Keywords: Petroleum. Logistics. Simulation. Optimization.

1. Introduction

In 2016, Brazilian petroleum production has grown for third consecutive year, with 3.2% of annual growth, reaching 918.7 billion barrels. From this total, 94% of the production is from offshore fields, with Pre-salt responsible for 40.6% of national production (ANP, 2017). In this setting, offshore exploration and production activities at Pre-salt basin unveiled

¹ Master, Equipment Engineer – CENPES, Petrobras

² Master, Production Engineer – COPPE/UFRJ

³ Petroleum Engineer – COPPE/UFRJ

⁴ Master, Production Engineer – COPPE/UFRJ

⁵ Master, Production Engineer – COPPE/UFRJ

⁶ Ph.D., Operational Research Analyst – CENPES, Petrobras

⁷ Ph.D., Production Engineer, Titular Professor – COPPE, UFRJ

A.3 Computers & Industrial Engineering

Journal Pre-proofs

A solution framework for the integrated problem of cargo assignment, fleet sizing, and delivery planning in offshore logistics

Gustavo Cunha de Bittencourt, Rennan Danilo Seimetz Chagas, Victor Anselmo Silva, Igor Girão Peres Vianna, Rafael Pedro Longhi, Paulo Cesar Ribas, Virgílio José Martins Ferreira Filho

PII: S0360-8352(21)00557-X
DOI: <https://doi.org/10.1016/j.cie.2021.107653>
Reference: CAIE 107653


To appear in: *Computers & Industrial Engineering*

Received Date: 11 October 2020
Accepted Date: 29 August 2021

Please cite this article as: de Bittencourt, G.C., Seimetz Chagas, R.D., Silva, V.A., Peres Vianna, I.G., Longhi, R.P., Ribas, P.C., Martins Ferreira Filho, V.J., A solution framework for the integrated problem of cargo assignment, fleet sizing, and delivery planning in offshore logistics, *Computers & Industrial Engineering* (2021), doi: <https://doi.org/10.1016/j.cie.2021.107653>

This is a PDF file of an article that has undergone enhancements after acceptance, such as the addition of a cover page and metadata, and formatting for readability, but it is not yet the definitive version of record. This version will undergo additional copyediting, typesetting and review before it is published in its final form, but we are providing this version to give early visibility of the article. Please note that, during the production process, errors may be discovered which could affect the content, and all legal disclaimers that apply to the journal pertain.

© 2021 Published by Elsevier Ltd.



A.4 Optimization and Engineering

Optimization and Engineering
<https://doi.org/10.1007/s11081-022-09723-6>

RESEARCH ARTICLE



A solution framework for the integrated periodic supply vessel planning and port scheduling in oil and gas supply logistics

Rennan Danilo Seimetz Chagas¹ · Juliana Beatriz Carvalho de Oliveira Soares¹ · Rafael Pedro Longhi¹ · Bruno Ferreira Vieira² · Edilson Fernandes de Arruda³ · Laura Silvia Bahiense da Silva Leite¹ · Virgílio José Martins Ferreira Filho¹

Received: 7 October 2021 / Revised: 11 February 2022 / Accepted: 2 April 2022
© The Author(s), under exclusive licence to Springer Science+Business Media, LLC, part of Springer Nature 2022

Abstract

In this study, we deal with a real-world problem on oil and gas upstream logistics, comprehending the transport of goods from ports to maritime units, through vessels called Platform Supply Vessels (PSVs). We present an integrated methodology to define the routes of these vessels and port schedules in a three-phase framework. In the first phase, we decompose the problem using a clustering heuristic and then solve periodic supply vessel routing problems for each cluster. The second phase employs a mixed-integer programming model for port scheduling and berth allocation. Finally, in the third phase, given port departure times, the routes are re-sequenced to respect opening time constraints at installations, aiming to reduce waiting times and to balance the intervals between successive services. The framework was validated and evaluated considering a real scenario from an industrial partner located in Rio de Janeiro, Brazil. The experiments' results revealed that the framework could consistently and significantly outperform the solution adopted by the company in terms of economic costs.

Keywords Offshore logistics · Supply vessel planning · Berth allocation problem · Mixed-integer programming · Periodic vessel routing problem

Juliana Beatriz Carvalho de Oliveira Soares, Rafael Pedro Longhi, Bruno Ferreira Vieira, Edilson Fernandes de Arruda, Laura Silvia Bahiense da Silva Leite and Virgílio José Martins Ferreira Filho have contributed equally to this work.

✉ Rennan Danilo Seimetz Chagas
rschagas@ufrj.br

Extended author information available on the last page of the article

Published online: 23 April 2022

Springer

Apêndice B

Trabalhos submetidos em revisão

B.1 Computers & Industrial Engineering

Relax-and-fix heuristics for the Multi-Commodity PSV Planning Problem With Order Selection and Time Window Decisions

Rennan Danilo Seimetz Chagas^a, Virgílio José Martins Ferreira Filho^{a,*}

^a*Department of Industrial Engineering, Federal University of Rio de Janeiro, Brazil*

Abstract

In Brazil, large oil reserves have been discovered in deep water over the years. The distance from the Brazilian coast as well as the depth of oil reserves leads to a great logistical effort from the point of view of supply operation. The literature on PSV operations planning is rich, but few studies have focused on the order selection problem. In this work, we present a formulation for an order selection problem, called Multi-Commodity Supply Vessel Planning Problem with Order Selection and Time Window Decisions. We present a method to generate artificial instances and solve this model by comparing two different ways to implement a relax-and-fix heuristic. The results show the importance of choosing the appropriate problem decomposition for designing a relax-and-fix heuristic.

Keywords: offshore logistics, supply vessel planning, relax-and-fix heuristic, order selection

1. Acknowledgments

We acknowledge the cooperation of Petroleo Brasileiro S.A. (Petrobras) which suggested this problem to us as a real demand for them and provided data sets and funding in the form of research grants.

This work was conducted during scholarships supported by CAPES – Brazilian Federal Agency for Support and Evaluation of Graduate Education, by the National Council for Scientific and Technological Development - CNPq and by Petrobras - Petroleo Brasileiro S.A.

*Corresponding author

Email addresses: `rennan.chagas@coppe.ufrj.br` (Rennan Danilo Seimetz Chagas),
`virgilio@ufrj.br` (Virgílio José Martins Ferreira Filho)

Preprint submitted to Computers & Industrial Engineering

July 24, 2022

Apêndice C

Resultados completos dos experimentos com a metaheurística ALNS

Instância	Meta-heurística	Critério	Solução Inicial	Objetivo			cpu	Objective-score		
				min	mean	max		min	mean	max
G10-C60-V14-P4	ALNS	HC	Aleatória	4136.99	4464.36	5187.58	563.49	1.07	1.16	1.34
G10-C60-V14-P4	ALNS	LHC	Aleatória	4144.73	4505.55	5000.78	591.58	1.07	1.17	1.30
G10-C60-V14-P4	ALNS	HC	Gulosa randomizada	4180.53	4422.68	4646.27	575.15	1.08	1.15	1.20
G10-C60-V14-P4	ALNS	LHC	Gulosa randomizada	4155.70	4329.05	4636.50	611.08	1.08	1.12	1.20
G10-C60-V14-P4	ALNS-b	HC	Aleatória	4150.48	4366.98	4658.39	361.10	1.08	1.13	1.21
G10-C60-V14-P4	ALNS-b	LHC	Aleatória	4194.18	4448.59	4695.67	366.82	1.09	1.15	1.22
G10-C60-V14-P4	ALNS-b	HC	Gulosa randomizada	4138.22	4365.01	4589.06	360.97	1.07	1.13	1.19
G10-C60-V14-P4	ALNS-b	LHC	Gulosa randomizada	4131.08	4382.32	4665.34	381.82	1.07	1.14	1.21
G10-C60-V8-P4	ALNS	HC	Aleatória	5417.15	5506.19	5810.20	533.33	1.23	1.25	1.32
G10-C60-V8-P4	ALNS	LHC	Aleatória	5302.60	5583.97	5820.18	518.38	1.20	1.27	1.32
G10-C60-V8-P4	ALNS	HC	Gulosa randomizada	5283.02	5421.56	5463.88	557.84	1.20	1.23	1.24
G10-C60-V8-P4	ALNS	LHC	Gulosa randomizada	5287.09	5416.39	5454.94	573.10	1.20	1.23	1.24
G10-C60-V8-P4	ALNS-b	HC	Aleatória	5289.45	5434.06	5592.01	351.10	1.20	1.23	1.27
G10-C60-V8-P4	ALNS-b	LHC	Aleatória	5405.19	5447.80	5497.98	367.80	1.23	1.24	1.25
G10-C60-V8-P4	ALNS-b	HC	Gulosa randomizada	5287.14	5402.14	5466.38	350.38	1.20	1.23	1.24
G10-C60-V8-P4	ALNS-b	LHC	Gulosa randomizada	5293.59	5427.91	5461.95	359.85	1.20	1.23	1.24
G11-C60-V15-P1	ALNS	HC	Aleatória	271.45	292.81	313.65	57.92	1.06	1.14	1.22
G11-C60-V15-P1	ALNS	LHC	Aleatória	271.04	288.34	302.84	58.28	1.06	1.13	1.18
G11-C60-V15-P1	ALNS	HC	Gulosa randomizada	271.04	289.79	312.36	54.34	1.06	1.13	1.22
G11-C60-V15-P1	ALNS	LHC	Gulosa randomizada	271.04	286.44	310.81	57.68	1.06	1.12	1.21
G11-C60-V15-P1	ALNS-b	HC	Aleatória	271.04	278.74	283.49	40.14	1.06	1.09	1.11
G11-C60-V15-P1	ALNS-b	LHC	Aleatória	271.04	282.35	309.71	41.74	1.06	1.10	1.21
G11-C60-V15-P1	ALNS-b	HC	Gulosa randomizada	271.04	276.94	290.23	39.84	1.06	1.08	1.13
G11-C60-V15-P1	ALNS-b	LHC	Gulosa randomizada	271.04	281.52	292.74	42.96	1.06	1.10	1.14
G11-C60-V15-P2	ALNS	HC	Aleatória	1904.89	2188.98	2502.99	466.10	1.09	1.26	1.44
G11-C60-V15-P2	ALNS	LHC	Aleatória	1905.75	2194.11	2593.31	437.69	1.10	1.26	1.49
G11-C60-V15-P2	ALNS	HC	Gulosa randomizada	1890.70	2068.12	2126.09	499.97	1.09	1.19	1.22
G11-C60-V15-P2	ALNS	LHC	Gulosa randomizada	1906.19	2080.55	2301.19	498.78	1.10	1.20	1.32
G11-C60-V15-P2	ALNS-b	HC	Aleatória	1898.59	2075.21	2136.01	324.71	1.09	1.19	1.23
G11-C60-V15-P2	ALNS-b	LHC	Aleatória	1916.89	2098.41	2220.18	339.10	1.10	1.21	1.28
G11-C60-V15-P2	ALNS-b	HC	Gulosa randomizada	1921.03	2085.76	2120.23	315.13	1.10	1.20	1.22
G11-C60-V15-P2	ALNS-b	LHC	Gulosa randomizada	1918.04	2085.81	2139.38	339.23	1.10	1.20	1.23
G11-C60-V9-P1	ALNS	HC	Aleatória	548.29	611.82	683.81	51.24	2.26	2.52	2.81
G11-C60-V9-P1	ALNS	LHC	Aleatória	546.95	594.72	685.08	47.72	2.25	2.45	2.82
G11-C60-V9-P1	ALNS	HC	Gulosa randomizada	546.70	586.99	643.96	50.92	2.25	2.42	2.65
G11-C60-V9-P1	ALNS	LHC	Gulosa randomizada	546.70	607.69	685.08	52.89	2.25	2.50	2.82
G11-C60-V9-P1	ALNS-b	HC	Aleatória	548.29	614.92	684.26	35.82	2.26	2.53	2.82
G11-C60-V9-P1	ALNS-b	LHC	Aleatória	546.70	603.51	683.58	35.58	2.25	2.48	2.81
G11-C60-V9-P1	ALNS-b	HC	Gulosa randomizada	529.87	592.40	684.26	36.30	2.18	2.44	2.82
G11-C60-V9-P1	ALNS-b	LHC	Gulosa randomizada	560.60	615.82	683.33	36.20	2.31	2.53	2.81
G11-C60-V9-P2	ALNS	HC	Aleatória	2429.86	2579.45	2959.21	372.91	1.21	1.29	1.48
G11-C60-V9-P2	ALNS	LHC	Aleatória	2430.53	2578.14	2946.56	290.12	1.21	1.29	1.47
G11-C60-V9-P2	ALNS	HC	Gulosa randomizada	2428.52	2472.21	2601.32	460.79	1.21	1.23	1.30

Continua na próxima página

Instância	Meta-heurística	Critério	Solução Inicial	Objetivo			cpu	Objective-score		
				min	mean	max		min	mean	max
G11-C60-V9-P2	ALNS	LHC	Gulosa randomizada	2429.22	2480.79	2679.13	404.62	1.21	1.24	1.34
G11-C60-V9-P2	ALNS-b	HC	Aleatória	2429.36	2504.99	2578.18	274.86	1.21	1.25	1.29
G11-C60-V9-P2	ALNS-b	LHC	Aleatória	2428.17	2490.15	2599.95	288.29	1.21	1.24	1.30
G11-C60-V9-P2	ALNS-b	HC	Gulosa randomizada	2425.35	2469.42	2540.75	308.50	1.21	1.23	1.27
G11-C60-V9-P2	ALNS-b	LHC	Gulosa randomizada	2430.76	2479.64	2552.19	325.90	1.21	1.24	1.27
G12-C60-V10-P3	ALNS	HC	Aleatória	4063.45	4173.03	4488.15	531.19	1.33	1.37	1.47
G12-C60-V10-P3	ALNS	LHC	Aleatória	3919.47	4153.74	4461.86	520.18	1.28	1.36	1.46
G12-C60-V10-P3	ALNS	HC	Gulosa randomizada	4062.81	4078.99	4272.32	564.96	1.33	1.34	1.40
G12-C60-V10-P3	ALNS	LHC	Gulosa randomizada	3921.06	4072.62	4274.68	570.09	1.28	1.33	1.40
G12-C60-V10-P3	ALNS-b	HC	Aleatória	4066.31	4074.85	4098.26	338.18	1.33	1.34	1.34
G12-C60-V10-P3	ALNS-b	LHC	Aleatória	3933.06	4079.54	4233.70	333.95	1.29	1.34	1.39
G12-C60-V10-P3	ALNS-b	HC	Gulosa randomizada	3927.16	4060.41	4099.42	341.94	1.29	1.33	1.34
G12-C60-V10-P3	ALNS-b	LHC	Gulosa randomizada	3930.49	4060.34	4092.51	348.03	1.29	1.33	1.34
G12-C60-V17-P3	ALNS	HC	Aleatória	2994.73	3200.51	3695.93	567.50	1.09	1.17	1.35
G12-C60-V17-P3	ALNS	LHC	Aleatória	2930.65	3264.84	3792.09	572.08	1.07	1.19	1.39
G12-C60-V17-P3	ALNS	HC	Gulosa randomizada	2928.42	3117.35	3243.02	574.35	1.07	1.14	1.19
G12-C60-V17-P3	ALNS	LHC	Gulosa randomizada	2925.00	3077.98	3238.08	558.80	1.07	1.12	1.18
G12-C60-V17-P3	ALNS-b	HC	Aleatória	2957.98	3063.98	3193.26	331.69	1.08	1.12	1.17
G12-C60-V17-P3	ALNS-b	LHC	Aleatória	2919.53	3070.39	3223.78	348.94	1.07	1.12	1.18
G12-C60-V17-P3	ALNS-b	HC	Gulosa randomizada	2964.56	3044.51	3208.45	358.93	1.08	1.11	1.17
G12-C60-V17-P3	ALNS-b	LHC	Gulosa randomizada	2994.64	3105.73	3225.82	378.00	1.09	1.13	1.18
G15-C90-V13-P2	ALNS	HC	Aleatória	3434.80	3680.22	4131.12	544.17	1.24	1.32	1.49
G15-C90-V13-P2	ALNS	LHC	Aleatória	3438.59	3699.35	4187.31	521.04	1.24	1.33	1.51
G15-C90-V13-P2	ALNS	HC	Gulosa randomizada	3431.65	3635.58	3738.92	536.90	1.23	1.31	1.34
G15-C90-V13-P2	ALNS	LHC	Gulosa randomizada	3488.27	3634.22	3843.62	535.42	1.25	1.31	1.38
G15-C90-V13-P2	ALNS-b	HC	Aleatória	3489.44	3639.85	3845.64	351.88	1.25	1.31	1.38
G15-C90-V13-P2	ALNS-b	LHC	Aleatória	3492.28	3646.67	3836.93	360.96	1.26	1.31	1.38
G15-C90-V13-P2	ALNS-b	HC	Gulosa randomizada	3570.91	3655.92	3842.15	350.67	1.28	1.31	1.38
G15-C90-V13-P2	ALNS-b	LHC	Gulosa randomizada	3459.15	3627.27	3729.94	345.78	1.24	1.30	1.34
G15-C90-V22-P2	ALNS	HC	Aleatória	3098.33	3154.45	3208.91	560.44	1.12	1.14	1.16
G15-C90-V22-P2	ALNS	LHC	Aleatória	3107.58	3272.60	3768.50	549.74	1.13	1.19	1.37
G15-C90-V22-P2	ALNS	HC	Gulosa randomizada	3092.93	3170.15	3420.03	584.09	1.12	1.15	1.24
G15-C90-V22-P2	ALNS	LHC	Gulosa randomizada	3096.31	3144.13	3197.24	569.81	1.12	1.14	1.16
G15-C90-V22-P2	ALNS-b	HC	Aleatória	2968.43	3086.44	3246.77	362.62	1.08	1.12	1.18
G15-C90-V22-P2	ALNS-b	LHC	Aleatória	2952.15	3148.49	3329.75	367.59	1.07	1.14	1.21
G15-C90-V22-P2	ALNS-b	HC	Gulosa randomizada	2953.81	3056.81	3183.66	356.97	1.07	1.11	1.15
G15-C90-V22-P2	ALNS-b	LHC	Gulosa randomizada	2949.25	3076.58	3193.01	374.63	1.07	1.11	1.16
G16-C90-V14-P3	ALNS	HC	Aleatória	5886.78	6116.59	6805.14	613.20	1.19	1.23	1.37
G16-C90-V14-P3	ALNS	LHC	Aleatória	5890.04	6161.15	6641.81	612.66	1.19	1.24	1.34
G16-C90-V14-P3	ALNS	HC	Gulosa randomizada	5879.59	5956.47	6206.50	631.00	1.18	1.20	1.25
G16-C90-V14-P3	ALNS	LHC	Gulosa randomizada	5893.94	6015.00	6384.97	614.89	1.19	1.21	1.29
G16-C90-V14-P3	ALNS-b	HC	Aleatória	5887.01	6021.62	6122.40	367.58	1.19	1.21	1.23
G16-C90-V14-P3	ALNS-b	LHC	Aleatória	5894.42	6062.57	6332.61	384.65	1.19	1.22	1.28
G16-C90-V14-P3	ALNS-b	HC	Gulosa randomizada	5876.72	5957.66	6121.35	372.03	1.18	1.20	1.23
G16-C90-V14-P3	ALNS-b	LHC	Gulosa randomizada	5903.58	6006.31	6236.26	396.87	1.19	1.21	1.26
G16-C90-V14-P4	ALNS	HC	Aleatória	8279.15	8443.75	8868.39	619.80	1.28	1.31	1.38
G16-C90-V14-P4	ALNS	LHC	Aleatória	8257.49	8431.39	8845.79	615.93	1.28	1.31	1.37
G16-C90-V14-P4	ALNS	HC	Gulosa randomizada	8132.98	8328.57	8551.39	679.89	1.26	1.29	1.33
G16-C90-V14-P4	ALNS	LHC	Gulosa randomizada	8157.00	8309.61	8353.69	647.50	1.27	1.29	1.30
G16-C90-V14-P4	ALNS-b	HC	Aleatória	8161.60	8260.19	8394.38	375.12	1.27	1.28	1.30
G16-C90-V14-P4	ALNS-b	LHC	Aleatória	8214.57	8337.20	8443.07	417.40	1.27	1.29	1.31
G16-C90-V14-P4	ALNS-b	HC	Gulosa randomizada	8068.34	8237.07	8345.36	391.71	1.25	1.28	1.29
G16-C90-V14-P4	ALNS-b	LHC	Gulosa randomizada	8207.46	8265.24	8385.89	413.96	1.27	1.28	1.30
G16-C90-V24-P3	ALNS	HC	Aleatória	4873.06	5150.14	5917.40	622.53	1.12	1.18	1.36
G16-C90-V24-P3	ALNS	LHC	Aleatória	4873.03	5230.06	5913.50	617.70	1.12	1.20	1.35
G16-C90-V24-P3	ALNS	HC	Gulosa randomizada	4813.51	4931.82	5074.02	645.79	1.10	1.13	1.16
G16-C90-V24-P3	ALNS	LHC	Gulosa randomizada	4811.01	4955.45	5112.47	631.58	1.10	1.14	1.17
G16-C90-V24-P3	ALNS-b	HC	Aleatória	4717.07	4906.33	5063.00	380.65	1.08	1.12	1.16
G16-C90-V24-P3	ALNS-b	LHC	Aleatória	4796.56	4975.79	5143.11	406.85	1.10	1.14	1.18
G16-C90-V24-P3	ALNS-b	HC	Gulosa randomizada	4697.61	4805.57	4955.31	392.15	1.08	1.10	1.14
G16-C90-V24-P3	ALNS-b	LHC	Gulosa randomizada	4704.46	4925.47	5108.21	405.39	1.08	1.13	1.17
G16-C90-V24-P4	ALNS	HC	Aleatória	6718.78	6930.55	7688.72	639.99	1.12	1.16	1.28
G16-C90-V24-P4	ALNS	LHC	Aleatória	6705.38	6927.37	7613.34	651.20	1.12	1.16	1.27
G16-C90-V24-P4	ALNS	HC	Gulosa randomizada	6712.89	6902.62	6969.11	670.97	1.12	1.15	1.16
G16-C90-V24-P4	ALNS	LHC	Gulosa randomizada	6829.35	6914.75	6985.03	657.40	1.14	1.15	1.17
G16-C90-V24-P4	ALNS-b	HC	Aleatória	6774.38	6868.95	6947.78	407.08	1.13	1.15	1.16
G16-C90-V24-P4	ALNS-b	LHC	Aleatória	6649.43	6831.93	6960.53	436.33	1.11	1.14	1.16
G16-C90-V24-P4	ALNS-b	HC	Gulosa randomizada	6637.80	6824.23	6940.28	429.20	1.11	1.14	1.16
G16-C90-V24-P4	ALNS-b	LHC	Gulosa randomizada	6624.41	6811.34	6935.58	424.26	1.11	1.14	1.16
G17-C90-V15-P1	ALNS	HC	Aleatória	668.52	764.88	1001.24	68.72	2.48	2.83	3.71
G17-C90-V15-P1	ALNS	LHC	Aleatória	558.10	772.41	971.98	72.88	2.07	2.86	3.60
G17-C90-V15-P1	ALNS	HC	Gulosa randomizada	668.00	741.88	850.77	73.60	2.48	2.75	3.15
G17-C90-V15-P1	ALNS	LHC	Gulosa randomizada	592.71	739.23	857.88	74.04	2.20	2.74	3.18
G17-C90-V15-P1	ALNS-b	HC	Aleatória	604.28	733.30	831.56	43.35	2.24	2.72	3.08
G17-C90-V15-P1	ALNS-b	LHC	Aleatória	668.00	765.51	845.87	52.07	2.48	2.84	3.13

Continua na próxima página

Instância	Meta-heurística	Critério	Solução Inicial	Objetivo			cpu	Objective-score		
				min	mean	max		min	mean	max
G17-C90-V15-P1	ALNS-b	HC	Gulosa randomizada	628.25	735.36	829.19	47.10	2.33	2.73	3.07
G17-C90-V15-P1	ALNS-b	LHC	Gulosa randomizada	597.36	736.90	902.42	46.09	2.21	2.73	3.34
G17-C90-V25-P1	ALNS	HC	Aleatória	355.95	377.88	491.71	82.87	1.54	1.63	2.12
G17-C90-V25-P1	ALNS	LHC	Aleatória	357.97	389.91	507.80	88.06	1.55	1.68	2.19
G17-C90-V25-P1	ALNS	HC	Gulosa randomizada	358.14	363.93	388.05	108.30	1.55	1.57	1.68
G17-C90-V25-P1	ALNS	LHC	Gulosa randomizada	338.55	366.45	388.57	94.20	1.46	1.58	1.68
G17-C90-V25-P1	ALNS-b	HC	Aleatória	355.25	367.26	388.05	67.79	1.53	1.59	1.68
G17-C90-V25-P1	ALNS-b	LHC	Aleatória	355.25	371.48	389.78	61.79	1.53	1.60	1.68
G17-C90-V25-P1	ALNS-b	HC	Gulosa randomizada	327.57	357.69	378.73	76.82	1.41	1.54	1.63
G17-C90-V25-P1	ALNS-b	LHC	Gulosa randomizada	341.04	356.76	376.87	73.38	1.47	1.54	1.63
G21-C120-V19-P1	ALNS	HC	Aleatória	1313.73	1516.07	1852.24	182.70	2.22	2.56	3.13
G21-C120-V19-P1	ALNS	LHC	Aleatória	1313.73	1499.27	1889.27	180.03	2.22	2.53	3.19
G21-C120-V19-P1	ALNS	HC	Gulosa randomizada	1310.66	1444.74	1572.32	200.20	2.22	2.44	2.66
G21-C120-V19-P1	ALNS	LHC	Gulosa randomizada	1310.50	1438.72	1525.79	198.47	2.22	2.43	2.58
G21-C120-V19-P1	ALNS-b	HC	Aleatória	1256.81	1396.19	1630.95	129.46	2.12	2.36	2.76
G21-C120-V19-P1	ALNS-b	LHC	Aleatória	1310.50	1462.00	1677.60	130.65	2.22	2.47	2.84
G21-C120-V19-P1	ALNS-b	HC	Gulosa randomizada	1201.28	1415.48	1571.44	133.62	2.03	2.39	2.66
G21-C120-V19-P1	ALNS-b	LHC	Gulosa randomizada	1299.85	1413.93	1566.84	132.43	2.20	2.39	2.65
G21-C120-V19-P2	ALNS	HC	Aleatória	3625.90	3852.33	4360.94	609.64	1.22	1.29	1.46
G21-C120-V19-P2	ALNS	LHC	Aleatória	3637.72	3818.97	4275.03	583.21	1.22	1.28	1.43
G21-C120-V19-P2	ALNS	HC	Gulosa randomizada	3620.49	3782.24	4067.95	616.44	1.21	1.27	1.36
G21-C120-V19-P2	ALNS	LHC	Gulosa randomizada	3615.99	3747.52	4030.71	612.68	1.21	1.26	1.35
G21-C120-V19-P2	ALNS-b	HC	Aleatória	3611.25	3732.01	3907.15	388.77	1.21	1.25	1.31
G21-C120-V19-P2	ALNS-b	LHC	Aleatória	3619.16	3801.64	3977.24	390.43	1.21	1.28	1.33
G21-C120-V19-P2	ALNS-b	HC	Gulosa randomizada	3629.40	3754.05	3882.87	388.37	1.22	1.26	1.30
G21-C120-V19-P2	ALNS-b	LHC	Gulosa randomizada	3622.79	3772.24	3975.65	391.91	1.22	1.27	1.33
G21-C120-V32-P1	ALNS	HC	Aleatória	816.71	859.67	990.71	291.68	1.17	1.23	1.41
G21-C120-V32-P1	ALNS	LHC	Aleatória	814.87	879.76	1074.80	277.48	1.16	1.26	1.53
G21-C120-V32-P1	ALNS	HC	Gulosa randomizada	818.86	859.10	1008.03	280.10	1.17	1.23	1.44
G21-C120-V32-P1	ALNS	LHC	Gulosa randomizada	821.37	864.73	898.79	307.39	1.17	1.23	1.28
G21-C120-V32-P1	ALNS-b	HC	Aleatória	810.08	855.80	993.98	193.17	1.16	1.22	1.42
G21-C120-V32-P1	ALNS-b	LHC	Aleatória	814.56	898.58	1067.50	197.47	1.16	1.28	1.52
G21-C120-V32-P1	ALNS-b	HC	Gulosa randomizada	811.16	827.45	874.70	189.67	1.16	1.18	1.25
G21-C120-V32-P1	ALNS-b	LHC	Gulosa randomizada	810.08	850.65	939.24	200.50	1.16	1.21	1.34
G21-C120-V32-P2	ALNS	HC	Aleatória	3033.56	3172.75	3784.39	622.04	1.16	1.21	1.45
G21-C120-V32-P2	ALNS	LHC	Aleatória	3000.93	3161.22	3621.71	603.94	1.15	1.21	1.39
G21-C120-V32-P2	ALNS	HC	Gulosa randomizada	3003.82	3103.01	3313.69	638.05	1.15	1.19	1.27
G21-C120-V32-P2	ALNS	LHC	Gulosa randomizada	2994.64	3092.68	3172.38	652.26	1.15	1.18	1.21
G21-C120-V32-P2	ALNS-b	HC	Aleatória	2994.63	3073.51	3129.50	405.66	1.15	1.18	1.20
G21-C120-V32-P2	ALNS-b	LHC	Aleatória	3038.68	3152.28	3385.35	390.92	1.16	1.21	1.30
G21-C120-V32-P2	ALNS-b	HC	Gulosa randomizada	2982.93	3068.51	3178.13	382.20	1.14	1.17	1.22
G21-C120-V32-P2	ALNS-b	LHC	Gulosa randomizada	3029.49	3099.61	3171.63	397.71	1.16	1.19	1.21
G22-C120-V20-P3	ALNS	HC	Aleatória	8079.21	8354.87	9073.86	690.63	1.26	1.30	1.41
G22-C120-V20-P3	ALNS	LHC	Aleatória	8037.17	8304.24	8988.27	673.16	1.25	1.29	1.40
G22-C120-V20-P3	ALNS	HC	Gulosa randomizada	7975.97	8158.67	8370.28	702.58	1.24	1.27	1.30
G22-C120-V20-P3	ALNS	LHC	Gulosa randomizada	8074.45	8241.78	8634.13	702.59	1.25	1.28	1.34
G22-C120-V20-P3	ALNS-b	HC	Aleatória	8023.79	8218.05	8470.02	423.42	1.25	1.28	1.32
G22-C120-V20-P3	ALNS-b	LHC	Aleatória	8084.84	8290.17	8561.42	442.44	1.26	1.29	1.33
G22-C120-V20-P3	ALNS-b	HC	Gulosa randomizada	7964.15	8125.13	8266.56	443.23	1.24	1.26	1.28
G22-C120-V20-P3	ALNS-b	LHC	Gulosa randomizada	8023.08	8228.06	8412.48	440.60	1.25	1.28	1.31
G22-C120-V34-P3	ALNS	HC	Aleatória	6477.33	6657.11	7567.56	693.50	1.16	1.20	1.36
G22-C120-V34-P3	ALNS	LHC	Aleatória	6506.79	6640.60	7697.79	684.40	1.17	1.19	1.38
G22-C120-V34-P3	ALNS	HC	Gulosa randomizada	6419.14	6597.34	7093.31	723.19	1.15	1.19	1.28
G22-C120-V34-P3	ALNS	LHC	Gulosa randomizada	6428.34	6610.60	6736.73	725.45	1.16	1.19	1.21
G22-C120-V34-P3	ALNS-b	HC	Aleatória	6281.94	6465.70	6644.95	446.92	1.13	1.16	1.19
G22-C120-V34-P3	ALNS-b	LHC	Aleatória	6343.97	6511.16	6775.90	464.43	1.14	1.17	1.22
G22-C120-V34-P3	ALNS-b	HC	Gulosa randomizada	6292.47	6451.41	6573.37	450.52	1.13	1.16	1.18
G22-C120-V34-P3	ALNS-b	LHC	Gulosa randomizada	6352.15	6497.28	6711.24	469.56	1.14	1.17	1.21
G23-C120-V21-P4	ALNS	HC	Aleatória	10457.46	10779.22	11646.87	745.22	1.16	1.20	1.29
G23-C120-V21-P4	ALNS	LHC	Aleatória	10442.69	10876.09	11781.22	749.60	1.16	1.21	1.31
G23-C120-V21-P4	ALNS	HC	Gulosa randomizada	10430.43	10589.50	10875.34	766.39	1.16	1.17	1.21
G23-C120-V21-P4	ALNS	LHC	Gulosa randomizada	10450.79	10641.84	10905.02	750.43	1.16	1.18	1.21
G23-C120-V21-P4	ALNS-b	HC	Aleatória	10472.49	10644.74	10943.71	443.38	1.16	1.18	1.21
G23-C120-V21-P4	ALNS-b	LHC	Aleatória	10485.31	10806.90	11068.57	486.30	1.16	1.20	1.23
G23-C120-V21-P4	ALNS-b	HC	Gulosa randomizada	10416.28	10539.12	10626.96	499.62	1.16	1.17	1.18
G23-C120-V21-P4	ALNS-b	LHC	Gulosa randomizada	10438.74	10625.27	10776.53	490.98	1.16	1.18	1.20
G23-C120-V36-P4	ALNS	HC	Aleatória	8788.11	8928.67	9702.48	767.68	1.08	1.10	1.20
G23-C120-V36-P4	ALNS	LHC	Aleatória	8771.17	9018.31	10198.43	765.65	1.08	1.11	1.26
G23-C120-V36-P4	ALNS	HC	Gulosa randomizada	8763.53	8833.17	8931.87	779.70	1.08	1.09	1.10
G23-C120-V36-P4	ALNS	LHC	Gulosa randomizada	8785.33	8886.49	9131.52	801.24	1.08	1.10	1.13
G23-C120-V36-P4	ALNS-b	HC	Aleatória	8738.22	8813.87	8977.09	513.42	1.08	1.09	1.11
G23-C120-V36-P4	ALNS-b	LHC	Aleatória	8807.18	8963.28	9072.73	506.66	1.09	1.10	1.12
G23-C120-V36-P4	ALNS-b	HC	Gulosa randomizada	8680.69	8794.46	8946.00	523.99	1.07	1.08	1.10
G23-C120-V36-P4	ALNS-b	LHC	Gulosa randomizada	8742.55	8846.40	8989.57	525.83	1.08	1.09	1.11
G5-C30-V3-P1	ALNS	HC	Aleatória	537.84	546.92	600.88	21.50	1.85	1.88	2.07

Continua na próxima página

Instância	Meta-heurística	Critério	Solução Inicial	Objetivo			cpu	Objective-score		
				min	mean	max		min	mean	max
G5-C30-V3-P1	ALNS	LHC	Aleatória	537.84	543.74	594.36	21.32	1.85	1.87	2.05
G5-C30-V3-P1	ALNS	HC	Gulosa randomizada	537.84	540.48	558.32	21.06	1.85	1.86	1.92
G5-C30-V3-P1	ALNS	LHC	Gulosa randomizada	537.84	539.16	558.32	20.73	1.85	1.86	1.92
G5-C30-V3-P1	ALNS-b	HC	Aleatória	537.84	538.01	541.48	13.07	1.85	1.85	1.87
G5-C30-V3-P1	ALNS-b	LHC	Aleatória	537.84	538.71	541.48	12.53	1.85	1.86	1.87
G5-C30-V3-P1	ALNS-b	HC	Gulosa randomizada	537.84	537.84	537.84	13.31	1.85	1.85	1.85
G5-C30-V3-P1	ALNS-b	LHC	Gulosa randomizada	537.84	538.01	541.48	12.68	1.85	1.85	1.87
G5-C30-V3-P2	ALNS	HC	Aleatória	1525.47	1537.64	1600.55	235.06	1.33	1.34	1.40
G5-C30-V3-P2	ALNS	LHC	Aleatória	1525.47	1538.23	1600.84	195.41	1.33	1.34	1.40
G5-C30-V3-P2	ALNS	HC	Gulosa randomizada	1525.47	1525.72	1526.52	291.31	1.33	1.33	1.33
G5-C30-V3-P2	ALNS	LHC	Gulosa randomizada	1525.47	1525.90	1526.52	313.10	1.33	1.33	1.33
G5-C30-V3-P2	ALNS-b	HC	Aleatória	1525.47	1525.78	1526.52	241.95	1.33	1.33	1.33
G5-C30-V3-P2	ALNS-b	LHC	Aleatória	1525.47	1528.87	1588.55	226.08	1.33	1.34	1.39
G5-C30-V3-P2	ALNS-b	HC	Gulosa randomizada	1525.47	1525.86	1526.52	225.82	1.33	1.33	1.33
G5-C30-V3-P2	ALNS-b	LHC	Gulosa randomizada	1525.47	1525.85	1526.52	225.20	1.33	1.33	1.33
G5-C30-V3-P3	ALNS	HC	Aleatória	2185.51	2188.63	2190.61	95.36	1.15	1.15	1.15
G5-C30-V3-P3	ALNS	LHC	Aleatória	2185.51	2195.13	2240.06	47.62	1.15	1.16	1.18
G5-C30-V3-P3	ALNS	HC	Gulosa randomizada	2185.51	2187.22	2190.61	73.54	1.15	1.15	1.15
G5-C30-V3-P3	ALNS	LHC	Gulosa randomizada	2185.51	2189.25	2234.91	49.20	1.15	1.15	1.18
G5-C30-V3-P3	ALNS-b	HC	Aleatória	2185.51	2187.56	2190.61	49.59	1.15	1.15	1.15
G5-C30-V3-P3	ALNS-b	LHC	Aleatória	2185.51	2187.79	2190.61	49.66	1.15	1.15	1.15
G5-C30-V3-P3	ALNS-b	HC	Gulosa randomizada	2185.51	2187.83	2190.61	50.08	1.15	1.15	1.15
G5-C30-V3-P3	ALNS-b	LHC	Gulosa randomizada	2185.51	2188.18	2190.61	55.23	1.15	1.15	1.15
G5-C30-V3-P4	ALNS	HC	Aleatória	3286.79	3288.28	3289.01	380.16	1.32	1.32	1.32
G5-C30-V3-P4	ALNS	LHC	Aleatória	3286.79	3300.25	3415.77	379.05	1.32	1.33	1.37
G5-C30-V3-P4	ALNS	HC	Gulosa randomizada	3286.79	3288.58	3289.04	413.61	1.32	1.32	1.32
G5-C30-V3-P4	ALNS	LHC	Gulosa randomizada	3286.79	3288.51	3289.04	402.69	1.32	1.32	1.32
G5-C30-V3-P4	ALNS-b	HC	Aleatória	3288.37	3288.94	3290.10	322.38	1.32	1.32	1.32
G5-C30-V3-P4	ALNS-b	LHC	Aleatória	3286.79	3288.82	3290.35	326.54	1.32	1.32	1.32
G5-C30-V3-P4	ALNS-b	HC	Gulosa randomizada	3288.86	3289.27	3289.86	318.57	1.32	1.32	1.32
G5-C30-V3-P4	ALNS-b	LHC	Gulosa randomizada	3288.86	3289.19	3289.85	329.16	1.32	1.32	1.32
G5-C30-V6-P1	ALNS	HC	Aleatória	252.90	269.49	340.28	23.37	1.86	1.98	2.50
G5-C30-V6-P1	ALNS	LHC	Aleatória	245.52	262.13	352.21	22.94	1.81	1.93	2.59
G5-C30-V6-P1	ALNS	HC	Gulosa randomizada	252.90	252.90	252.90	24.27	1.86	1.86	1.86
G5-C30-V6-P1	ALNS	LHC	Gulosa randomizada	245.52	252.20	252.90	23.60	1.81	1.85	1.86
G5-C30-V6-P1	ALNS-b	HC	Aleatória	245.52	251.49	252.90	15.00	1.81	1.85	1.86
G5-C30-V6-P1	ALNS-b	LHC	Aleatória	245.52	251.49	252.90	14.42	1.81	1.85	1.86
G5-C30-V6-P1	ALNS-b	HC	Gulosa randomizada	245.52	252.20	252.90	15.71	1.81	1.85	1.86
G5-C30-V6-P1	ALNS-b	LHC	Gulosa randomizada	245.52	252.20	252.90	15.48	1.81	1.85	1.86
G5-C30-V6-P2	ALNS	HC	Aleatória	1028.82	1217.78	1387.75	303.59	1.30	1.54	1.75
G5-C30-V6-P2	ALNS	LHC	Aleatória	1028.01	1235.97	1375.04	255.88	1.30	1.56	1.74
G5-C30-V6-P2	ALNS	HC	Gulosa randomizada	1024.05	1167.73	1235.04	399.23	1.29	1.47	1.56
G5-C30-V6-P2	ALNS	LHC	Gulosa randomizada	1024.05	1171.39	1235.47	418.75	1.29	1.48	1.56
G5-C30-V6-P2	ALNS-b	HC	Aleatória	1029.47	1193.83	1234.75	268.52	1.30	1.51	1.56
G5-C30-V6-P2	ALNS-b	LHC	Aleatória	1027.50	1161.78	1232.78	287.97	1.30	1.47	1.56
G5-C30-V6-P2	ALNS-b	HC	Gulosa randomizada	1023.34	1126.53	1228.58	289.25	1.29	1.42	1.55
G5-C30-V6-P2	ALNS-b	LHC	Gulosa randomizada	1025.55	1122.20	1236.43	293.12	1.29	1.42	1.56
G5-C30-V6-P3	ALNS	HC	Aleatória	1611.07	1709.01	1901.32	285.48	1.24	1.31	1.46
G5-C30-V6-P3	ALNS	LHC	Aleatória	1638.55	1736.15	1941.91	311.68	1.26	1.33	1.49
G5-C30-V6-P3	ALNS	HC	Gulosa randomizada	1614.42	1653.80	1671.68	363.46	1.24	1.27	1.28
G5-C30-V6-P3	ALNS	LHC	Gulosa randomizada	1618.96	1661.60	1674.30	389.70	1.24	1.28	1.29
G5-C30-V6-P3	ALNS-b	HC	Aleatória	1611.05	1656.23	1674.78	259.77	1.24	1.27	1.29
G5-C30-V6-P3	ALNS-b	LHC	Aleatória	1613.52	1648.91	1670.80	231.77	1.24	1.27	1.28
G5-C30-V6-P3	ALNS-b	HC	Gulosa randomizada	1620.54	1659.10	1674.30	275.13	1.25	1.27	1.29
G5-C30-V6-P3	ALNS-b	LHC	Gulosa randomizada	1618.34	1659.03	1674.78	276.15	1.24	1.27	1.29
G5-C30-V6-P4	ALNS	HC	Aleatória	2817.33	2882.64	3062.19	520.82	1.28	1.31	1.39
G5-C30-V6-P4	ALNS	LHC	Aleatória	2819.14	2881.05	3050.22	511.71	1.28	1.31	1.39
G5-C30-V6-P4	ALNS	HC	Gulosa randomizada	2815.58	2826.14	2835.62	555.25	1.28	1.29	1.29
G5-C30-V6-P4	ALNS	LHC	Gulosa randomizada	2820.78	2826.75	2833.53	549.85	1.28	1.29	1.29
G5-C30-V6-P4	ALNS-b	HC	Aleatória	2820.30	2830.79	2844.87	311.65	1.28	1.29	1.29
G5-C30-V6-P4	ALNS-b	LHC	Aleatória	2813.31	2830.98	2845.43	319.92	1.28	1.29	1.29
G5-C30-V6-P4	ALNS-b	HC	Gulosa randomizada	2817.66	2830.44	2843.30	325.86	1.28	1.29	1.29
G5-C30-V6-P4	ALNS-b	LHC	Gulosa randomizada	2817.87	2831.15	2843.09	336.82	1.28	1.29	1.29