Otimização de Carregamentos de embarcações Pipe Laying Support Vessel

Raphael Domingues de Lacerda Bittencourt[1,2], Rachel Martins Ventriglia[1,2], Davi Zerpini Mecler[1,2], Luana Mesquita Carrilho[1,2], Bruno Fanzeres Santos[1], Pedro Teixeira Cardoso Lobato[2], Gabriela Ribas Klein,[2]

[1] Departamento de Engenharia Industrial, PUC-Rio

[2] Instituto Tecgraf, PUC-Rio

R. Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ, 22452-900

raphadombit@gmail.com, rachelventriglia@gmail.com, davizm@tecgraf.puc-rio.br, luanamc@tecgraf.puc-rio.br, bruno.santos@puc-rio.br, pedro.lobato@tecgraf.puc-rio.br, gabriela.ribas@tecgraf.puc-rio.br

RESUMO

As embarcações *Pipe-laying Support Vessel* (PLSV) realizam tarefas de interligação submarinas, sendo essa a última etapa necessária para que o poço possa produzir óleo. Para realizar essa atividade é necessário o carregamento de diversos materiais. Estes carregamentos podem ser realizados em diferentes berços, e a sua duração é considerada uma incerteza na sua programação. Com o objetivo de auxiliar no planejamento operacional dos carregamentos, este trabalho propôs a elaboração de um modelo de otimização cuja função objetivo é minimizar o tempo de término dos carregamentos, ponderado pelas suas prioridades e as respectivas penalidades de utilização dos berços. Para modelar a incerteza da duração, foi desenvolvido um modelo de previsão, utilizando o algoritmo de *Random Forest*, que apresentou um erro percentual médio absoluto de 45%. O modelo estocástico desenvolvido encontra uma solução ótima em aproximadamente 40 minutos, utilizando 60 cenários, mostrando ser uma boa alternativa para auxiliar no planejamento dos carregamentos.

PALAVRAS CHAVE. Carregamentos, Programação de Máquinas Paralelas, Modelo Estocástico.

Tópicos: Pesquisa Operacional, Petróleo e Gás, Otimização

ABSTRACT

Pipe-laying Support Vessels (PLSV) perform subsea interconnection tasks, which is the last step necessary for the well to produce oil. To perform this activity, it is necessary to load several materials. These loadings can be done in different berths, and their duration is considered an uncertainty in their schedule. To assist in the operational planning of the loads, this work proposed the elaboration of a mathematical model whose objective function is to minimize the weighted completion time of loads, and the respective penalties for the use of the berths. To model the uncertainty of the duration, a predictive model was developed, using a Random Forest algorithm, which presented a mean absolute percentage error of 45%. The stochastic mathematical model developed finds an optimal solution in approximately 40 minutes, using 60 scenarios, proving to be a good alternative to assist in the operational planning of shipments.

KEYWORDS. Loading, Parallel Machine Programming, Stochastic Model.

Paper topics: Operational Research, Oil and Gas, Optimization

https://proceedings.science/p/157589?lang=pt-br

1. Introdução

A exploração e produção de petróleo e gás *offshore* apresentam diversos desafios, como condições climáticas e longas distâncias entre as plataformas e terminais marítimos. Estes fatores são ainda mais importantes na exploração da camada de pré-sal do Brasil, que opera em profundidades superiores a 2.000 metros [Morais, 2013].

A embarcação *Pipe-laying Support Vessel* (PLSV) é um dos recursos mais críticos na exploração *offshore* de petróleo, sendo responsável pela interligação de poços submarinos. Este navio é um recurso limitado e de alto custo, aproximadamente $200 mil por dia para as empresas desta área [Bnamericas, 2021]. Por isso, é importante que o planejamento destas embarcações seja feito de forma a evitar ociosidades em seu cronograma.

A interligação de poços à unidade estacionária de produção é a última etapa necessária para que o poço possa produzir óleo, e é uma atividade cuja complexidade aumenta com a profundidade onde esta operação é realizada. São necessários diversos materiais para a realização da interligação, como: dutos rígidos, flexíveis ou uma combinação de ambos [Ferreira, 2013]. Estes materiais são carregados em vários locais de atracação, chamados de berços, localizados nos portos. Dessa forma, seu carregamento nas embarcações PLSV é uma etapa importante para a realização das operações de interligação e cumprimento do cronograma.

A motivação para este trabalho vem de um problema de planejamento de carregamentos para embarcações PLSV de uma empresa de óleo e gás. Atualmente, ela realiza este planejamento de forma manual, utilizando critérios subjetivos ao conhecimento do planejador. Além disso, não existe um critério bem definido de alocação dos carregamentos nos berços, dependendo na maioria das vezes apenas da disponibilidade do berço. Com isso, os cronogramas destas embarcações podem apresentar ociosidades, que são prejudiciais para a empresa do ponto de vista financeiro, dado que a diária desta embarcação possui um alto custo. Outro ponto importante é que atrasos no carregamento do PLSV podem impactar na produção de óleo dos poços, pois eles demorariam a serem conectados na plataforma, atrasando as operações da empresa e impactando na sua geração de receita.

É importante ressaltar que, apesar de existir um planejamento sobre a duração das atividades de carregamento dos PLSVs, existem fatores como condições climáticas ou aspectos humanos da operação que fazem com que a sua duração seja uma incerteza. Entretanto, devido ao planejamento manual e à subjetividade desta tarefa, não consegue-se garantir que esses fatores sejam considerados pela empresa ao realizar a programação dos carregamentos. Analisando os dados do horizonte de planejamento do curto prazo da operação, o erro percentual médio absoluto da duração dos carregamentos é de 84%, mostrando que em alguns casos esse planejamento não é o melhor possível.

Com isso, o principal objetivo do trabalho é propor um problema de otimização sob incerteza de carregamentos de embarcações PLSV, que busca minimizar a ociosidade dos navios e o impacto da utilização de berços mais caros para a empresa. Nesse trabalho, minimizar a ociosidade significa minimizar a soma do tempo de término dos carregamentos, ponderado pela suas prioridades. Dessa forma, será possível fazer uma comparação da solução do modelo matemático proposto com o planejamento manual da empresa.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta uma revisão da literatura que mostra a relevância do tema. A Seção 3 apresenta a descrição do problema, e a Seção 4 mostra como foi feita geração de cenários. Os resultados são apresentados na Seção 5, seguido das conclusões na Seção 6.

https://proceedings.science/p/157589?lang=pt-br

2. Revisão da Literatura

O problema de programação dos carregamentos para embarcações PLSV em berços pode ser modelado como um problema de programação de máquinas paralelas idênticas, que consiste em encontrar uma atribuição para n tarefas em m máquinas idênticas, onde cada tarefa deve ser realizada apenas uma vez e possui um tempo de processamento p [Mokotoff, 2004]. No nosso caso, as tarefas equivalem aos carregamentos e as máquinas aos berços.

Diferentes tipos de funções objetivos e restrições podem ser abordadas para esses problemas. Nessah et al. [2008] utilizaram o algoritmo *branch and bound* com o intuito de minimizar o tempo total ponderado de conclusão em máquinas paralelas idênticas levando em consideração o *release date* das tarefas. Xu et al. [2013] buscaram minimizar o tempo de *makespan*, considerando que o tempo de processamento de cada tarefa é incerto, sendo estes um dos poucos trabalhos que consideram algum tipo de incerteza. Além disso, a resolução deste problema pode ser feita de diferentes maneiras, utilizando métodos exatos, como feito por Dell'Amico e Martello [2005], ou fazendo uso de heurísticas, como proposto por Al-Harkan et al. [2018].

Sobre a resolução de problemas de programação de embarcações PLSV, Abu-Marrul et al. [2020] utilizam o conceito de máquinas paralelas idênticas de modo a construir um cronograma para a frota de PLSVs destinada a atividades de interligação submarina, enquanto Mecler et al. [2022] expandem essa proposta utilizando 4 variações de um algoritmo baseado em *Iterated Greedy* para a resolução. Entretanto, para o melhor do nosso conhecimento, não existem trabalhos que tenham abordado a otimização do planejamento de carregamentos de embarcações PLSV, e por isso este trabalho poderia ajudar a suprir esta lacuna na literatura.

3. Descrição do Problema

Nesse trabalho, cada carregamento está associado a uma embarcação PLSV, e os carregamentos só podem começar depois da sua data de prontidão (r_j), também chamada de *release date*, sendo a menor data possível que a tarefa pode ser iniciada. Para realizar as operações de interligação de poços submarinos as embarcações precisam ser carregadas com materiais específicos desse serviço, tais como:

- Dutos Submarinos (Tramos): Tubulações especialmente desenvolvidas para transportar petróleo (óleo e/ou gás) dos poços de produção até a plataforma de petróleo.
- Umbilicais (UEH): Linha submarina rígida composta por um conjunto de mangueiras e cabos elétricos, utilizados para operar remotamente equipamentos e válvulas de produção e injeção.
- Flutuadores: Equipamento equivalente à uma boia responsável pela maior parte da força de empuxo, sendo necessário para minimizar a tensão vertical das linhas submarinas nas conexões da plataforma.
- Bobina: Carretel onde são armazenadas as linhas submarinas.

Esses materiais são carregados em bases de carregamento (portos) que possuem berços disponíveis, podendo pertencer à empresa ou não. Além disso, este problema possui algumas características como:

- Cada carregamento deve ser realizado apenas uma vez.
- Uma vez iniciado, o carregamento não pode ser interrompido.
- Um berço não pode realizar dois carregamentos ao mesmo tempo.

- Existe elegibilidade entre carregamento e berço, ou seja, alguns carregamentos só podem ser realizados em berços específicos.
- Cada carregamento possui uma prioridade diferente, relacionada ao seu propósito.

Como existem restrições sobre em quais berços os carregamentos podem ser feitos, a decisão de alocação dos carregamentos nos berços é realizada antes da decisão a respeito da data do carregamento. Por isso, o modelo matemático proposto é um modelo de dois estágios, onde a decisão de primeiro estágio é a alocação dos carregamentos nos berços, e a decisão de segundo estágio é alocar estes carregamentos no tempo e nos berços definidos no primeiro estágio. Além disso, a função objetivo escolhida visa minimizar a utilização dos berços que não pertencem à empresa, junto com a minimização da soma do tempo de término dos carregamentos, de forma a evitar que eles fiquem ociosos. A seguir, o modelo desenvolvido é detalhado, com as respectivas definições de conjuntos, parâmetros e variáveis de decisão. O modelo utiliza uma formulação de *time-index* [Sousa e Wolsey, 1992], que pode ser utilizada em qualquer discretização do horizonte de planejamento.

Sets:
$j \in J$ set de carregamentos
$k \in K$ set de berços
$t \in T$ set de períodos
$s \in \Omega$ set de cenários

Parâmetros:
r_j data de prontidão (*release date*) do carregamento j
$e_{j,k}$ elegibilidade do carregamento j no berço k
u_k penalidade de usar o berço k
w_j prioridade/peso do carregamento j
$p_{j,s}$ tempo de processamento do carregamento j
$Prob_s$ probabilidade do cenário s

Variáveis:
$X_{j,k,t,s}$ é igual a 1 se o carregamento j é alocado no berço k no tempo t e no cenário s, e 0 caso contrário
$C_{j,s}$ define tempo de término (*completion time*) do carregamento j no cenário s
$Y_{j,k}$ é igual a 1 se o carregamento j é alocado no berço k, e 0 caso contrário (variável de primeiro estágio)

Função Objetivo (FO):

$$\min \sum_{j \in J, s \in \Omega} Prob_s * w_j * C_{j,s} + \sum_{j \in J, k \in K} u_k * Y_{j,k} \tag{1}$$

$$\text{s.t.} \sum_{t \in T, k \in K} X_{j,k,t,s} = 1, \ \forall j \in J, \forall s \in \Omega \tag{2}$$

$$\sum_{j \in J} \sum_{t' \geq t - p_{j,s}+1}^{t} X_{j,k,t',s} \leq 1, \ \forall k \in K, \forall j \in J, \forall s \in \Omega \tag{3}$$

$$C_{j,s} \geq \sum_{t \in T, k \in K} X_{j,k,t,s} * (t - 1 + p_{j,s}),\ \forall j \in J, \forall s \in \Omega \tag{4}$$

$$X_{j,k,t,s} \leq e_{j,k},\ \forall j \in J, \forall k \in K, \forall t \in T, \forall s \in \Omega \tag{5}$$

$$X_{j,k,t,s} \leq Y_{j,k},\ \forall j \in J, \forall k \in K, \forall t \in T, \forall s \in \Omega \tag{6}$$

$$\sum_{k \in K} Y_{j,k} = 1,\ \forall j \tag{7}$$

$$X_{j,k,t,s} \in \{0, 1\},\ \forall j \in J, \forall k \in K, \forall t \in T, \forall s \in \Omega | t > r_j \tag{8}$$

$$C_{j,s} \geq 0, \forall j \in J, \forall s \in \Omega \tag{9}$$

$$Y_{j,k} \in \{0, 1\},\ \forall j \in J, \forall k \in K \tag{10}$$

Como mencionado anteriormente, a função objetivo (1) busca minimizar o tempo de término dos carregamentos, de acordo com suas prioridades e o impacto da utilização de berços que não pertencem à empresa, ou seja, os carregamentos mais prioritários serão alocados mais cedo, tentando utilizar os berços que possuem uma menor, ou nenhuma, penalidade. A equação (2) garante que cada carregamento é realizado apenas uma vez, e a equação (3) diz que não há sobreposição de carregamentos no mesmo berço. A equação (4) afirma que o tempo de término do carregamento deve ser maior ou igual à sua duração após ser alocada no tempo t. Já a equação (5) garante que um carregamento j só é alocado no berço k se existir elegibilidade entre esse carregamento e o berço. A equação (6) certifica-se que cada carregamento j só é alocado no berço que foi definido pela variável de primeiro estágio. Por fim a equação (7) garante que cada carregamento j só pode ser alocado em apenas um berço. As equações (8), (9) e (10) definem o domínio das variáveis.

4. Geração de cenários

Para modelar a incerteza do tempo de processamento, foi desenvolvido um modelo preditivo capaz de prever a duração dos carregamentos para o horizonte de planejamento do curso prazo da operação. Devido à não remoção de *outliers* no dado utilizado, a técnica escolhida para esse problema foi o *Random Forest*, um modelo composto por várias árvores de decisão, e que é robusto à *outliers* e ruídos no dado. Além disso, é um modelo rápido, simples e facilmente paralelizável [Breiman, 2001].

Utilizando dados de carregamento de uma empresa de óleo e gás, foi realizada uma análise exploratória dos dados, para entender seu comportamento em relação à duração dos carregamentos. Ao todo a base de dados possui aproximadamente 560 registros de carregamentos, com atributos referentes ao planejamento do carregamento, como o nome do berço, nome da base, nome da embarcação, e quantidades referentes aos materiais carregados.

Com uma análise quantitativa dos atributos numéricos, foi possível observar que alguns atributos possuíam mais de 75% de seus valores iguais a zero, indicando que estes materiais em questão raramente eram carregados, e por isso eles provavelmente não teriam bom desempenho no modelo preditivo. Assim, foi utilizado *feature engineering* para juntar alguns destes atributos,

fazendo com que os atributos numéricos restantes fossem apenas: quantidade total linhas, comprimento total de linhas, quantidade de flutuadores e quantidade de bobinas.

Utilizando uma técnica de seleção de variáveis chamada *Correlation Based Feature Selection*, que avalia e indica subconjuntos que contém atributos altamente correlacionados com a variável resposta e não correlacionados entre si, foram escolhidos três atributos para serem utilizados como variáveis explicativas do modelo de previsão: Nome da Base, Quantidade de Linhas Totais e Quantidade de Flutuadores.

Após a definição das variáveis, a base de dados foi dividida a fim de separar os dados a serem utilizados no modelo matemático. Eles correspondem ao horizonte de planejamento do curto prazo da operação (com 58 carregamentos), e são previstos separadamente, após o treinamento e avaliação do modelo. O restante dos dados foi dividido em treinamento (80%) e teste (20%). Com a base de treinamento, foi feita uma busca pelos melhores hiperparâmetros para o modelo e, por fim, ele foi treinado e avaliado na base de teste e nos dados da otimização. O resultado das métricas de avaliação está apresentado na Tabela 1. As métricas escolhidas foram o erro médio absoluto (MAE), erro médio quadrático (MSE), erro percentual médio absoluto (MAPE) e R2 Score, métricas comuns para problemas de regressão. Avaliando o resultado do modelo nos dados, pode-se concluir que ele apresentou um bom desempenho, com MAE e MSE baixos em ambas as bases de dados, e um R2 alto, indicando que os preditores escolhidos conseguem explicar mais de 60% dos dados de teste e 70% dos dados da otimização. Apesar do erro percentual estar alto nos dois dados, de 32% no dado de teste e 45% no dado da otimização, é uma melhora significativa em comparação com o planejamento manual feito atualmente pela empresa nesse mesmo período, que possui um erro percentual médio absoluto de 84%.

	MAE	MSE	R2 Score	MAPE
Dados de Teste	1.04	2.53	0.62	32%
Dados da otimização	0.70	0.97	0.70	45%

Tabela 1: Resultado do Random Forest na base de teste e na base de dados de 2022

Depois de realizar a previsão da duração de 58 carregamentos, a geração de cenários para resolver o problema de otimização foi feita calculando o erro entre a duração real e a previsão do modelo e ajustando essa distribuição de erros a uma distribuição de probabilidade. Com o auxílio do *Python* 3.9.7 e o pacote *Fitter*, foi possível avaliar que distribuições se ajustaram melhor ao erro calculado, e o resultado está apresentado na Tabela 2.

	Sum Squared Error	AIC	BIC
Laplace	3.00	689.19	-253.81
Cauchy	3.08	617.39	-251.86
Normal Inverse Gaussian	3.10	596.88	-242.53
Student's t	3.18	656.74	-244.82
Non-Central Student's t	3.23	610.23	-239.34

Tabela 2: Melhores distribuições para o erro de previsão

A Tabela 2 apresenta diferentes critérios para a escolha da melhor distribuição que caracteriza os dados. A segunda coluna representa a soma do erro quadrado, uma medida da erro

entre os dados e a distribuição analisada e sendo assim, quanto menor o valor obtido melhor é a distribuição. Já a terceira e a quarta colunas, representam o *Akaike's Information Criterion* (AIC) e o *Bayesian Information Criterion* (BIC), respectivamente. Esses critérios buscam identificar qual é a melhor distribuição que representa os dados do problema, e quanto menor o valor obtido, melhor é a distribuição [Chakrabarti e Ghosh, 2011]. Para esse trabalho foi considerado que a distribuição que retorna o menor erro quadrado seria a melhor escolha, e por isso foi escolhida a Laplace. Além disso, também é possível visualizar graficamente o resultado das distribuições ajustadas ao erro calculado da previsão (Figura 1).

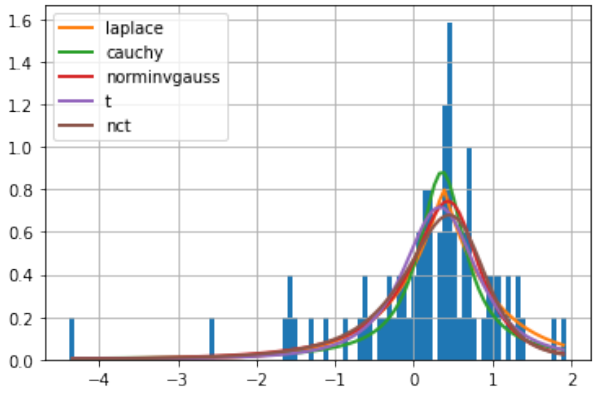


Figura 1: Gráfico das melhores distribuições para o erro de previsão

Por fim, a distribuição de erros foi ajustada a uma distribuição Laplace com os parâmetros $\mu = 0.379$ e $\theta = 0.615$. Com isso, a geração de cenários foi feita gerando 58 números aleatórios, referentes aos 58 carregamentos que seriam planejados pelo modelo matemático, para cada cenário, a partir desta distribuição e somando-os à previsão do *Random Forest*.

Como a formulação do modelo matemático é uma formulação time index [Sousa e Wolsey, 1992], onde os períodos de tempo são inteiros no horizonte de planejamento, e a previsão do modelo nos dá valores que não são inteiros, foi necessário realizar um tratamento da duração dos carregamentos gerada em cada cenário, para que o valor final fosse um número inteiro. Este tratamento foi feito em duas etapas: (i) ajuste dos decimais; e (ii) transformação para um valor inteiro.

Atualmente, o planejamento dos carregamentos na empresa é feito considerando um quarto de dia, ou seja, o dia é dividido em quatro períodos de seis horas. Dessa forma, caso um carregamento se inicie às 13 horas, por esse critério, ele será planejado para ocorrer no terceiro período do dia, às 12 horas. Com isso, na etapa (i) os valores decimais foram ajustados para serem iguais à 0, 0.25, 0.50, 0.75 ou 1. A etapa (ii) consistiu em multiplicar os novos valores por 4 para transformá-los em números inteiros e seguir o mesmo planejamento da empresa.

5. Resultados e Discussão

Para ilustrar a metodologia proposta, foi utilizada uma instância baseada em dados de uma empresa de óleo e gás, com os 3 primeiros meses de planejamento operacional. Ao todo, esta instância possui 58 carregamentos e 6 berços para planejamento, dos quais 3 pertencem a empresa, 1 possui acordo comercial e os últimos 2 não pertencem a empresa.

O dado de prioridade dos carregamentos foi calculado utilizando a prioridade estabelecida pela empresa, e adicionando a esse valor um acréscimo, para dar um peso maior para carregamentos de poços produtores de óleo e de atividades especiais relacionadas às manutenção das embarcações.

A data de prontidão foi calculada como 5 dias antes do início do carregamento planejado manualmente pela empresa. Este valor foi escolhido com base nas análises dos processos manuais da empresa. Por fim, o parâmetro de penalidade foi escolhido atribuindo zero para os berços que pertenciam à empresa, 100 para os berços que possuem um acordo de parceria e 500 para berços que não pertencem à empresa.

O algoritmo foi desenvolvido na linguagem de programação Julia 1.7 e compilado no *Visual Studio Code*. Para a resolução do problema foi utilizado a versão 9.5.0 do solver GUROBI no ambiente JuMP 1.1.0. Todos os experimentos foram rodados no Windows 10 64-bit com i7-5960X CPU @ 3.00GHz e 64 GB de RAM.

Por ser um modelo matemático de dois estágios, a decisão de primeiro estágio não depende dos cenários, e é a mesma para todos os cenários testados. Na Tabela 3, é apresentado a quantidade de carregamentos alocados em cada berço, mostrando o resultado da decisão de primeiro estágio do modelo. É possível observar que o modelo consegue alocar a maioria dos carregamentos em berços pertencentes à empresa, diminuindo a penalidade de alocação, mas devido à restrição de elegibilidade, alguns carregamentos ainda precisam ser feitos em berços que não pertencem à empresa, como o 5 e 6.

	Berço 1	Berço 2	Berço 3	Berço 4	Berço 5	Berço 6
Quantidade de Carregamentos	13	13	0	29	1	2

Tabela 3: Resultado da decisão de primeiro estágio, referente à alocação dos carregamentos nos berços

O modelo foi rodado variando a quantidade de cenários utilizados com os valores de 10, 20, 30, 40, 50 e 60. Na figura 2 é possível observar o tempo de execução total, o tempo de otimização e o tempo de construção do modelo pela quantidade de cenários utilizados. Analisando o gráfico, percebe-se que o comportamento do tempo de solução do modelo é bastante impactado com o aumento do número de cenários, enquanto o tempo de construção não é tão influenciado por essa alteração.

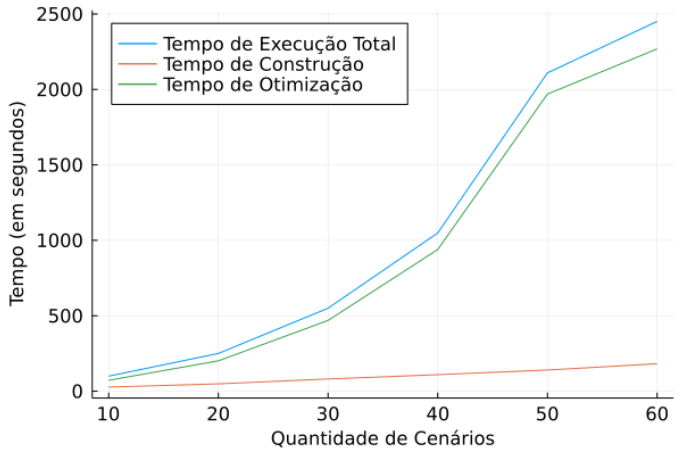


Figura 2: Tempo de execução, construção e otimização do modelo pela quantidade de cenários utilizados

Além disso, foram analisadas as quantidades de variáveis, restrições e valor da FO, para cada quantidade de cenário escolhida, apresentados na Tabela 4. É possível observar, nos casos

analisados, que o valor da função objetivo (FO) quase não alterou, com uma diferença menor que 0.02% entre a maior FO e a menor. Por outro lado, ao analisar a quantidade de variáveis e restrições, vemos que o aumento é significativo à medida que a quantidade de cenários aumenta. Além disso, o tempo total de execução também apresenta uma grande discrepância, de 100 segundos (aproximadamente 2 minutos) com 10 cenários para 2450 segundos (aproximadamente 40 minutos) com 60 cenários.

Quantidade de Cenários	FO	Quantidade de Variáveis	Quantidade de Restrições	Tempo Total (segundos)
10	41424.71	1.45 x 10^6	2.45 x 10^6	100
20	41453.57	2.66 x 10^6	4.90 x 10^6	250
30	41400.52	3.87 x 10^6	7.34 x 10^6	550
40	41398.57	5.08 x 10^6	9.79 x 10^6	1048
50	41462.90	6.29 x 10^6	12.25 x 10^6	2109
60	41406.27	7.50 x 10^6	14.70 x 10^6	2450

Tabela 4: Comparação entre cenários

Ao analisar o comportamento das durações geradas para cada quantidade de cenários, podemos observar na Figura 3 que os cenários possuem uma maior volatilidade, em comparação com o dado real. Isso significa que ao tratar o problema de forma estocástica, estamos considerando uma maior quantidade de duração possíveis e nos prevenindo para os piores casos que podem acontecer. Como o valor da FO quase não foi alterado (vide Tabela 4), o modelo estocástico poderia utilizar apenas 10 cenários, e já obteria um bom resultado. Por outro lado, optando-se por uma abordagem mais conservadora, faria sentido utilizar um modelo com 50 ou 60 cenários, que ainda possuem um tempo razoável de execução (entre 35 e 40 minutos), e consideram piores casos de durações, como é possível ver pelas caudas maiores destes gráficos.

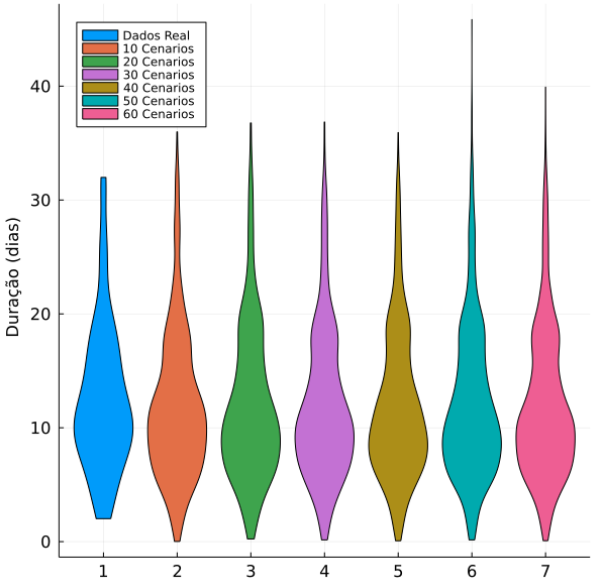


Figura 3: Violin plot para diferentes cenários

Utilizando a solução do modelo com 60 cenários, foram calculados dois indicadores es-

tocásticos, o valor esperado da informação perfeita (EVPI) e o valor da solução estocástica (VSS), para medir a qualidade da solução. O EVPI indica a diferença entre saber a realização da incerteza para tomar a decisão e utilizar um modelo estocástico, enquanto o VSS mede o benefício de utilizar um modelo estocástico, ao invés de tratar a incerteza como a média dos cenários de duração dos carregamentos [Birge e Louveaux, 1997]. A Tabela 5 mostra o resultado dos indicadores mencionados anteriormente, onde podemos ver que o EVPI foi baixo, indicando que está próximo da informação perfeita, e o VSS foi positivo, mostrando a vantagem de utilizar o modelo em comparação com a média da incerteza.

Indicador Estocástico	Resultado
EVPI	14.13
VSS	25.57

Tabela 5: Resultado do cálculo dos indicadores estocásticos

Além disso, foi realizada uma comparação do planejamento manual realizado atualmente pela empresa com o modelo determinístico e estocástico, apresentado na Figura 4. O primeiro apresentou uma FO de 46356.70 e o segundo de 40808.20, mostrando que o modelo matemático determinístico obteve uma melhora de 12% em relação ao planejamento manual. Considerando o modelo estocástico com 60 cenários, que obteve uma FO de 41406.27, a melhora foi de 11%. Além disso, ao observar os valores de FO do modelo estocástico, podemos concluir que com poucos cenários a solução já converge, devido à baixa variação de FO entre os cenários.

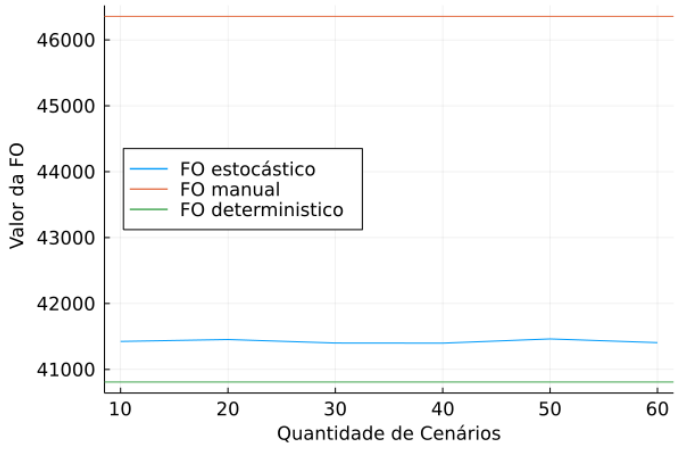


Figura 4: Comparação do resultados das funções objetivos (FO)

Com base na Figura 4, pode-se afirmar que o modelo matemático desenvolvido neste trabalho foi capaz de encontrar de forma automática uma solução de programação dos carregamentos ótima e menor do que a da empresa, tanto de forma determinística e quanto estocástica. Enquanto o determinístico retorna um menor valor de FO, em pouco tempo de execução (aproximadamente 1 minuto), ele não considera diferentes cenários, sendo menos robusto. O modelo estocástico considera essa variação de cenários de duração, resolvendo o problema com 60 cenários em um tempo razoável. A utilização dos modelos ao invés da forma manual traz vantagens para os programadores por ser uma solução ótima que pode ser obtida em pouco tempo, e consegue garantir que as

restrições do problema sejam atendidas.

6. Conclusão

As embarcações PLSV são recursos críticos na exploração e produção de petróleo e gás *offshore*, que realizam operações de interligação de poços submarinos. Para isso é necessário que os navios sejam carregados com os materiais referentes à suas operações. Estes carregamentos podem ser realizados em diferentes berços, e a sua duração, apesar de ser planejada, está sujeita a fatores como condições climáticas, atrasos das embarcações ou aspectos humanos da operação. Atualmente a programação destes carregamentos é feita de maneira manual e sem levar em consideração esta incerteza, e por isso pode não ser o planejamento mais adequado.

Com o intuito de auxiliar no planejamento operacional dos carregamentos, este trabalho propôs a elaboração de um modelo matemático cujo objetivo é minimizar o tempo de término dos carregamentos, ponderado pelas suas prioridades e as respectivas penalidades de utilização dos berços, para gerar uma programação ótima dos carregamentos. Para modelar a incerteza da duração, foram utilizados dados de empresa de óleo e gás, de um período de 4 anos. Um modelo de previsão da duração dos carregamentos foi desenvolvido, utilizando o algoritmo de *Random Forest*, que apresentou um erro percentual de 45% nos dados utilizados pelo modelo matemático.

O primeiro experimento computacional realizado foi para encontrar a quantidade de cenários a ser utilizada no modelo, e com isso observou-se que com o aumento no número de cenários a função objetivo começa a convergir. Uma análise mais detalhada mostrou que a quantidade de variáveis, quantidade de restrições e o tempo total de execução do modelo cresce consideravelmente com este aumento. Apesar desse fato, o valor definido para o cálculo dos indicadores estocástico foi de 60 cenários visto que 40 minutos ainda é um tempo razoável de resolução e considera uma grande variação de durações, conferindo uma maior segurança para os piores caso.

O modelo matemático estocástico desenvolvido encontra uma solução ótima em aproximadamente 40 minutos, com um valor de 41406.27 unidades. Calculando o EVPI e o VSS, foram obtidos os valores de 14.13 e 25.57, respectivamente. Por fim, foi realizada uma comparação entre a solução manual da empresa e o modelo proposto, onde foi possível concluir que o modelo matemático estocástico deste trabalho é capaz de encontrar rapidamente uma solução ótima com um resultado aproximadamente 11% melhor do que o obtido pelo planejamento da empresa, mostrando ser uma boa alternativa para auxiliar na tomada de decisão e no planejamento operacional dos carregamentos.

Como trabalhos futuros, sugere-se estudar outras formas de modelar a incerteza do problema, testando mais técnicas de aprendizado de máquinas como por exemplo modelos baseados em redes neurais. Além disso, recomenda-se estudar outras possíveis funções objetivos para o problema, como funções de custo, que indicam de forma mais tangível o impacto do modelo no planejamento dos carregamentos.

Referências

Abu-Marrul, V., Martinelli, R., e Hamacher, S. (2020). Scheduling pipe laying support vessels with non-anticipatory family setup times and intersections between sets of operations. *International Journal of Production Research*, 59.

Al-Harkan, I., Bamatraf, K., Noman, M., Kaid, H., Abouel Nasr, E., e A.M., E.-T. (2018). An order effect of neighborhood structures in variable neighborhood search algorithm for minimizing the makespan in an identical parallel machine scheduling. *Mathematical Problems in Engineering*, 2018.

Birge, J. e Louveaux, F. (1997). Introduction to stochastic programming.

Bnamericas (2021). Petrobras to hire brazilian pipelay vessels. URL https://www.bnamericas.com/en/analysis/petrobras-to-hire-brazilian-pipelay-vessels. Acessado em 20 de junho de 2022.

Breiman, L. (2001). Random forests. *Machine Learning*, 45:5–32.

Chakrabarti, A. e Ghosh, J. (2011). Aic, bic and recent advances in model selection. *Philosophy of Statistics*, 7:583–605.

Dell'Amico, M. e Martello, S. (2005). A note on exact algorithms for the identical parallel machine scheduling problem. *European Journal of Operational Research*, 160(2):576–578.

Ferreira, D. (2013). As principais operações das embarcações plsv. Master's thesis.

Mecler, D., Abu-Marrul, V., Martinelli, R., e Hoff, A. (2022). Iterated greedy algorithms for a complex parallel machine scheduling problem. *European Journal of Operational Research*, 300 (2):545–560.

Mokotoff, E. (2004). An exact algorithm for the identical parallel machine scheduling problem. *European Journal of Operational Research*, 152:758–769.

Morais, J. M. (2013). Petróleo em águas profundas: uma história tecnológica da petrobras na exploração e produção offshore. Technical report, Instituto de Pesquisa Econômica Aplicada (Ipea), Petrobras, Rio de Janeiro.

Nessah, R., Yalaoui, F., e Chu, C. (2008). A branch-and-bound algorithm to minimize total weighted completion time on identical parallel machines with job release dates. *Computers Operations Research*, 35(4):1176–1190.

Sousa, J. P. e Wolsey, L. A. (1992). A time indexed formulation of non-preemptive single machine scheduling problems. *Mathematical Programming*, 54:353–367.

Xu, X., Cui, W., Lin, J., e Qian, Y. (2013). Robust makespan minimisation in identical parallel machine scheduling problem with interval data. *International Journal of Production Research*, 51.