



Silvia Helena Ferraro

**Modelagem para avaliação dos alívios críticos
em plataformas de petróleo**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre (opção profissional) pelo Programa de Pós-graduação em Engenharia Industrial do Departamento de Engenharia Industrial da PUC-Rio.

Orientador: Prof. Fernando Luiz Cyrino Oliveira

Rio de Janeiro
Setembro de 2020



Silvia Helena Ferraro

**Modelagem para avaliação dos alívios críticos
em plataformas de petróleo**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre (opção profissional) pelo Programa de Pós-graduação em Engenharia Industrial do Departamento de Engenharia Industrial da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Fernando Luiz Cyrino Oliveira

Orientador

Departamento de Engenharia Industrial – PUC/Rio

Marcelo Maciel Monteiro

Universidade Federal Fluminense

Prof. Reinaldo Castro Souza

Departamento de Engenharia Industrial – PUC/Rio

Rio de Janeiro, 22 de setembro de 2020

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização do autor, do orientador e da universidade.

Silvia Helena Ferraro

Graduou-se em Engenharia Química pela Universidade Estadual de Campinas (UNICAMP) em 2008. Iniciou suas atividades na Petróleo Brasileiro S.A. (Petrobras) em janeiro de 2010 e atualmente trabalha com logística de petróleo.

Ficha Catalográfica

Ferraro, Silvia Helena

Modelagem para avaliação dos alívios críticos em plataformas de petróleo / Silvia Helena Ferraro ; orientador: Fernando Luiz Cyrino Oliveira. – 2020.

46 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2020.

Inclui Bibliografia

1. Engenharia Industrial – Teses. 2. Alívios de plataforma. 3. Modelagem. 4. Regressão dinâmica. 5. Logística de petróleo. 6. Programação de alívios. I. Oliveira, Fernando Luiz Cyrino. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. III. Título.

CDD: 658.5

Agradecimentos

Agradeço aos meus pais, Carmen e Claudemir, e aos meus irmãos, Flávia e Luiz, que sempre estiveram comigo na minha formação pessoal e acadêmica e que me deram todo suporte e amor incondicional.

Ao meu marido Paulo, que me apoiou na decisão de iniciar o mestrado e esteve comigo em todos os momentos, me incentivando sempre a continuar e não desistir.

À minha filha Alice, que nasceu durante a elaboração desta dissertação, mas que me deu o tempo necessário para terminá-la.

Ao meu orientador, Professor Fernando Luiz Cyrino Oliveira, pela paciência, pela confiança no meu trabalho, pelas dicas e por todo suporte prestado.

À Petrobras, pela oportunidade e pelo suporte concedidos, sem os quais este trabalho não poderia ter sido realizado.

Ao meu gerente, Ricardo Steffanello, e aos coordenadores Rodrigo Cruz e Luciana Nader, que sempre me incentivaram e viabilizaram a liberação para os dias de aula e de estudo.

Aos meus colegas de trabalho, que me incentivaram e me ajudaram com os estudos e com a elaboração desta dissertação.

E a todos aqueles que de alguma forma contribuíram e me incentivaram para a conclusão deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001

Resumo

Ferraro, Silvia Helena; Oliveira, Fernando Luiz Cyrino (Orientador). **Modelagem para avaliação dos alívios críticos em plataformas de petróleo.** Rio de Janeiro, 2020. 46p. Dissertação de Mestrado (Opção profissional) – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

A crescente produção de petróleo em águas brasileiras torna cada vez mais importante a gestão logística de alívios das plataformas produtoras. A programação de alívios das plataformas deve ser realizada de forma antecipativa, evitando a parada de produção por falta de espaço disponível para armazenagem. Uma interrupção da produção de petróleo, por menor que seja, causa uma perda direta de receita para a empresa produtora. Alívios realizados muito próximos ao completo enchimento de todos os tanques da plataforma representam risco iminente de perda de produção e são denominados alívios críticos. Este trabalho tem como objetivo realizar um estudo estatístico com dados históricos de 2016 a 2019 para criar um modelo multivariado de previsão dos alívios críticos em uma grande empresa de petróleo brasileira. O modelo de regressão dinâmica foi utilizado para avaliar como as variáveis presentes no processo de programação de alívios se relacionam com o percentual mensal de alívios críticos. A partir do modelo gerado foram identificadas que as variáveis de produção mensal, estoque médio, previsão do tempo, lote médio e exportações mensais impactam no percentual de alívios críticos do mês. Foi realizada uma análise de sensibilidade, a partir da qual foi possível concluir que a gestão de estoques da empresa é o fator fundamental para a redução dos alívios críticos e consequentemente a redução das chances de perda de produção.

Palavras-chave

Alívios de plataforma; modelagem; regressão dinâmica; logística de petróleo; programação de alívios.

Abstract

Ferraro, Silvia Helena; Oliveira, Fernando Luiz Cyrino (Orientador). **Modeling for the assessment of critical offloadings on oil platforms.** Rio de Janeiro, 2020. 46p. MSc. Dissertation (Professional options) – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

The growing oil production in Brazilian waters makes the logistic management of offloadings from the platforms increasingly important. The platform offloading schedule must be carried out in advance, avoiding production stoppage due to lack of available storage space. An interruption in oil production, however small, causes a direct revenue loss for the producing company. Offloadings performed very close to the complete filling of all the platform tanks represent an imminent loss of production risk and are called critical offloadings. This work aims to carry out a statistical study with historical data from 2016 to 2019 to create a multivariate model for forecasting critical offloadings in a large Brazilian oil company. The dynamic regression model was used to evaluate how the variables present in the offloading scheduling process are related to the monthly percentage of critical offloadings. From the developed model, it was identified that the variables of monthly production, average stock, weather forecast, average batch and monthly exports impact the percentage of critical offloadings of the month. A sensitivity analysis was carried out, from which it was possible to conclude that the company's inventory management is the fundamental factor for the reduction of critical offloadings and, consequently, the reduction of the chances of production loss.

Keywords

Offloading; modeling; dynamic regression; oil logistics; offloading schedule.

Sumário

1	Introdução	8
2	Contextualização sobre processo de alívios em plataformas	12
2.1.	Frota de navios	12
2.2.	Alívios críticos	14
3	Revisão de Literatura	17
3.1.	Logística de alívios de plataformas de petróleo	17
3.2.	Utilização de métodos de previsão na indústria de óleo e gás	20
3.3.	Regressão dinâmica	21
3.4.	Análise dos erros	26
4	Modelagem	28
4.1.	Variáveis dependentes	28
4.2.	Variáveis independentes	29
4.3.	<i>Software</i> utilizado	31
5	Resultados e Discussões	32
5.1.	Alívios críticos com menos de 48 horas	32
5.1.1.	Análise de sensibilidade dos alívios críticos com menos de 48 horas	36
5.2.	Alívios críticos com menos de 24 horas	37
5.2.1.	Análise de sensibilidade dos alívios críticos com menos de 24 horas	40
6	Conclusões e Recomendações	43
7	Referências Bibliográficas	45

1 Introdução

A energia é uma das principais forças motrizes no desenvolvimento econômico de um país. Segundo Pereira Jr. et al. (2008) ela é um insumo fundamental para a produção de bens e serviços, além de aumentar o bem-estar da população, através do fornecimento de conforto térmico, luz e lazer, entre outros benefícios. Para Lin et al. (2017), a energia desempenha um papel fundamental na economia brasileira. O sucesso econômico recente do Brasil pode ser atribuído ao desenvolvimento do setor energético e sua infraestrutura. A figura 01 mostra a importância do petróleo e seus derivados na matriz energética brasileira, sendo responsável por 34,4% de todas as fontes de energia no país em 2018, conforme Empresa de Pesquisa Energética (EPE).




Figura 01 - Matriz energética brasileira em 2018. Adaptada de: EPE (2018).

Atualmente, a produção de petróleo é responsável por boa parte da economia mundial, e o Brasil é o décimo maior produtor de petróleo no mundo, responsável por aproximadamente 3% da produção mundial, conforme dados do Instituto Brasileiro de Petróleo, Gás e Biocombustíveis (IBP) mostrados nas figuras 2 e 3.




Figura 02 - Maiores produtores mundiais de petróleo em 2018. Adaptada de: IBP (2018).




Figura 03 - Percentual de produção de petróleo por país em 2018. Adaptada de: IBP (2018).

Nos últimos anos, os investimentos na área de exploração e produção vêm crescendo substancialmente no Brasil. Assim, o número de sistemas produtivos aumenta gradativamente, conforme dados de produção de 2009 a 2018 da Agência Nacional do Petróleo, Gás e Biocombustíveis (ANP) mostrados na figura 04.




Figura 04 - Produção de petróleo no Brasil ao longo dos últimos anos. Fonte de dados: ANP (2018).

Ainda segundo ANP, no Brasil, 4% do petróleo é produzido em terra e 96% é produzido em alto mar (*offshore*). As unidades de *Floating, Production, Storage e Offloading* (FPSOs) são muito populares na indústria de petróleo e gás (Meng et al., 2018). Elas são utilizadas para processar e armazenar temporariamente o petróleo e o gás que vêm das plataformas de produção ou diretamente dos poços do fundo do mar. Também conhecidos como plataformas de petróleo, é o tipo mais utilizado na indústria de petróleo brasileira. Cada uma possui características próprias, como capacidade de estocagem, taxa de produção diária e estoque mínimo, de forma a manter a estabilidade da unidade. Todo petróleo armazenado no FPSO é transferido periodicamente para navios aliviadores e destinado para os pontos de consumo.

O crescente aumento nas atividades *offshore* resulta em uma maior complexidade na logística necessária para escoamento da produção e serviços de apoio para continuidade da produção. Assim, as empresas estão sempre buscando alternativas para melhoria e otimização destas atividades, com objetivo de redução nos custos operacionais e melhoria na gestão logística.

Neste trabalho foi estudado uma empresa de produção de petróleo no Brasil que possui um grande número de plataformas de produção de petróleo. Para realizar o escoamento da produção *offshore* até os terminais aquaviários, esta empresa possui uma frota de navios aliviadores, que são navios específicos com tancagem interna para transporte de produtos líquidos.

À medida que ocorre a extração de petróleo, há o aumento do estoque na plataforma, tornando-se necessário escoar a produção para os navios aliviadores periodicamente, processo chamado de *offloading*. O *offloading* deve ser realizado antes do completo enchimento de todos os tanques da plataforma (TOP), para evitar perdas de produção de petróleo, que gerariam grandes perdas financeiras para a empresa por falta de espaço para armazenagem da produção. O nível de serviço logístico da área responsável pela programação das viagens dos navios é medido pelo atendimento à demanda de alívios de todas as plataformas da empresa.

Este trabalho tem o objetivo de avaliar como as variáveis presentes no dia-a-dia da equipe de logística desta empresa influenciam no atendimento à demanda de alívios das plataformas. Para isso, foi realizado um estudo baseado nas séries temporais históricas e, com a utilização do método de regressão dinâmica, foi elaborado um modelo de previsão de alívios críticos para os próximos meses. Além disso, foi realizada uma análise de sensibilidade, avaliando como essas variáveis impactam no nível de serviço logístico e nas decisões estratégicas da empresa.

Esta dissertação está dividida em 6 capítulos. O primeiro capítulo apresentado mostrou uma introdução ao trabalho e seu objetivo. O capítulo 2 traz uma contextualização do problema, com as particularidades da empresa estudada. No capítulo 3 é realizada uma revisão da literatura, apresentando os trabalhos referentes à logística de alívios de plataformas de petróleo, trabalhos no setor de petróleo e gás que utilizaram a regressão dinâmica e uma breve abordagem teórica sobre o método de regressão dinâmica. No capítulo 4 são apresentadas as variáveis que compõe o modelo. No capítulo 5 é feita a discussão dos resultados do modelo. E finalmente no capítulo 6 é apresentada a conclusão do trabalho e sugestões de estudos futuros.

2 Contextualização sobre processo de alívios em plataformas

A empresa em estudo foi responsável pela produção de 694 milhões de barris de petróleo em 2018 (ANP). Além das plataformas, esta empresa também possui refinarias, que processam o petróleo produzido. Para fechar o balanço de estoque, a empresa exporta a produção de petróleo excedente.

Mensalmente há um período de planejamento dos meses seguintes. Com a projeção de produção e refino de petróleo, os gestores decidem estrategicamente qual será o estoque médio em todo o sistema, incluindo refinarias, terminais, plataformas e navios. A partir de então, é possível definir qual será o volume de petróleo exportado para adequar o balanço de estoque.

Este estoque médio não pode ser muito alto, de forma que falte espaço para armazenamento de petróleo, e nem muito baixo, o que poderia causar uma redução no processamento das refinarias e, conseqüentemente, uma falta de derivados no mercado consumidor.

2.1. Frota de navios

O transporte de petróleo das plataformas até os terminais aquaviários é conhecido como cabotagem e, para atender esta demanda, a empresa possui uma frota cativa de navios aliviadores. Estes navios são contratados na modalidade TCP (*Time Charter Party*), ou seja, é feito um contrato de aluguel por um longo período e a gestão das viagens é feita pelo afretador.

Há um otimizador que realiza o planejamento da frota. Neste programa são inseridas as previsões de produção mensal de cada plataforma e também as restrições para o *offloading*, como tamanho máximo do lote e o tipo de navio adequado para a operação. Também são inseridos os dados dos navios, como capacidade, tipo, datas de manutenção e docagem.

A partir do resultado do otimizador, é avaliado o dimensionamento da frota. Se o número de navios da frota já contratada for maior que o número de navios necessário para o escoamento da produção, é analisada a possibilidade de entrega do navio para o armador ao final do contrato de aluguel. No outro extremo, se é apontada uma falta de navios na frota, é necessário negociar a contratação de mais navios, a fim de evitar redução da produção por limitação no transporte.

Essa contratação não é feita de forma rápida, pois a quantidade de navios disponíveis para cabotagem é escassa e normalmente esses navios já estão sendo utilizados por outras empresas ou então não cumprem os requisitos de segurança necessários para o afretamento. Assim, quando surge a demanda por mais navios, eles só são integrados à frota após meses, se for necessário aguardar o término do contrato com outra empresa, ou até mesmo anos, quando é preciso aguardar a construção do navio.

Além disso, ao longo do mês, alguns navios necessitam parar alguns dias para realizar pequenas manutenções, preventivas ou emergenciais. Estes dias em que os navios não estão aptos a realizar serviço de transporte são descontados do valor do aluguel e são chamados de *off-hire*. Estas paradas impactam diretamente na prestação de serviço da logística, pois não são planejadas com muita antecedência.

Os navios da frota podem ser classificados em convencionais, DP1 e DP2, a depender do tipo de posicionamento e amarração. Os navios convencionais não possuem sistema de posicionamento dinâmico e precisam ser auxiliados por rebocadores durante a operação de *offloading*. Já os navios DP, segundo Dong et al. (2017), mantêm posição exclusivamente por meios de propulsores ativos. Este sistema DP consiste em sistema de energia, sistema propulsor e sistema de controle do posicionamento dinâmico. A maior diferença entre os navios DP1 e DP2 é que o DP2 possui uma redundância no sistema DP, aumentando a segurança nas operações. As plataformas também necessitam do sistema de posicionamento relativo para operar com os navios DP. Dessa forma plataformas DP só operam com navio DP e plataformas convencionais só operam com navios convencionais.

Os navios também podem ser classificados de acordo com a tonelada de porte bruto (TPB), conforme tabela 01. Alguns terminais aquaviários possuem restrição para operação com navios muito grandes, assim a frota da empresa destinada para cabotagem é composta em sua maioria de navios Aframax e Suezmax.

Tabela 01 - Classificação dos navios

Classe do Navio	TPB
<i>MR</i>	45.000 a 55.000
<i>Panamax</i>	60.000 a 80.000
<i>Aframax</i>	80.000 a 120.000
<i>Suezmax</i>	120.000 a 170.000
<i>VLCC (Very Large Crude Carrier)</i>	200.000 a 315.000
<i>ULCC (Ultra Large Crude Carrier)</i>	315.000 a 550.000

Fonte: Adaptado pelo autor a partir de documentos internos da companhia

2.2. Alívios críticos

Como já foi citado, cada FPSO possui suas próprias características, como taxa de produção diária, capacidade de estocagem, lastro mínimo, vazão de *offloading*, entre muitas outras. Diariamente as plataformas enviam para a equipe de logística sua projeção de produção e as restrições de tancagem. É função da logística programar uma operação de alívio da plataforma antes que todos os seus tanques estejam cheios de petróleo (TOP). A figura 05 representa um TOP de plataforma. Como é mostrado, a partir do dia de TOP, a produção tem que ser zerada pois a capacidade máxima de estocagem da plataforma é atingida. Nessa simulação, o *offloading* deveria ser realizado até o sexto dia para evitar perda de produção de petróleo.

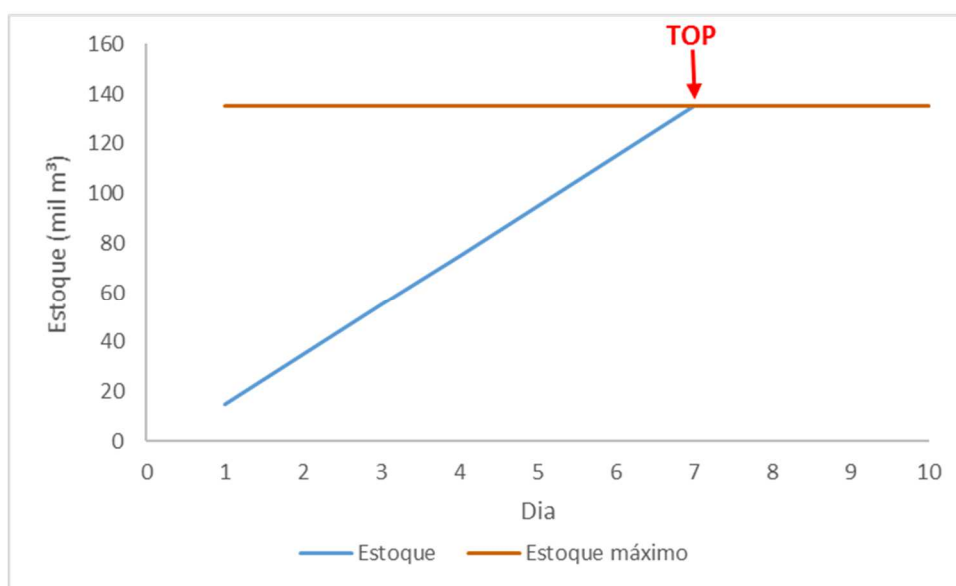


Figura 05 - Representação do TOP da plataforma. Fonte: Elaboração própria.

O TOP de qualquer plataforma é muito indesejável, visto que a perda de produção de petróleo tem impacto direto no faturamento da empresa. Considerando o preço médio do petróleo em 2018 de 71,31 US\$/barril (ANP) e uma produção de uma plataforma de 150.000 barris/dia, cada dia de parada de produção representa uma perda estimada de US\$ 10.696.500,00. Este valor mostra a importância da gestão logística dos alívios e a necessidade de atendimento à demanda de alívio das plataformas.

Para evitar que o TOP ocorra, a equipe de logística programa a chegada dos aliviadores até 48 horas antes da plataforma atingir seu estoque máximo. Considerando o exemplo da figura 05, o navio deveria ser programado para chegar antes do quinto dia. Os alívios que ocorrem com menos de 48 horas antes do TOP são chamados de alívios críticos.

No dia-a-dia ocorrem imprevistos que impactam na logística dos alívios e acabam resultando nos alívios críticos. Muitas vezes são necessárias manutenções programadas ou emergenciais nos navios, atrasando sua chegada na plataforma. Outras vezes ocorrem situações de mau tempo, nas quais os navios não conseguem amarrar nas plataformas ou nos terminais para descarga, atrasando as operações de *offloading*. Há também eventos de aumento da produção ou restrição de tancagem da plataforma, antecipando a data do TOP e gerando alívios críticos.

O percentual de alívios críticos em relação à quantidade total de alívios em todas as plataformas pode ser avaliado como o nível de serviço da logística. Quanto menor esse valor menor a chance de ocorrer o TOP da plataforma e consequentemente a perda de produção e perda financeira.

Atualmente é medida a quantidade de alívios com menos de 48 horas para o TOP e também a quantidade de alívios com menos de 24 horas para o TOP, sendo este último valor mais crítico, visto que aumenta as chances de perda de produção.

Na empresa estudada, não existe atualmente um modelo para previsão dos alívios críticos. São realizadas análises dos meses passados somente no âmbito operacional, sem uma ferramenta matemática que mostre a influência de variáveis do dia a dia e estratégicas na dinâmica de *offloadings*.

O desenvolvimento de um modelo estatístico para previsão dos alívios críticos traz muitas possibilidades de melhorias nos processos da empresa. A partir da informação de como as variáveis pertinentes à logística de *offloadings* se correlacionam, é possível tomar decisões, tanto estratégicas, como operacionais de

modo a minimizar os alvíos críticos e, conseqüentemente, o risco de perda de produção. Esse tipo de análise global resulta em um potencial retorno financeiro para a empresa, visto que o produto em questão possui alto valor agregado.

3 Revisão de Literatura

Neste capítulo serão apresentados os trabalhos da literatura que já estudaram a logística de alívios das plataformas. Também são mostrados trabalhos em que o método de regressão dinâmica é utilizado na indústria de óleo e gás. E finalmente são apresentadas as definições teóricas mais importantes para o entendimento do método de regressão dinâmica.

3.1. Logística de alívios de plataformas de petróleo

Foi realizada uma extensa pesquisa bibliográfica buscando referências sobre o que vem sendo estudado para melhoria da gestão logística dos alívios de plataformas. A grande maioria dos trabalhos trata da roteirização de navios para elaboração de um *scheduling* de alívios e dimensionamento da frota.

Assis e Camponogara (2016) pontuam que a programação dos navios-tanque é de suma importância para as operações nos campos de petróleo. Interromper a produção de uma plataforma devido à falta de capacidade de armazenamento não é aceitável, pois envolve o fechamento de poços. Além de ser uma operação complexa, fechar um poço é um procedimento arriscado que pode comprometer a produção futura: os poços podem levar um tempo considerável para voltar à plena operação e o tempo de inatividade da produção representa uma grande perda de receita. Por outro lado, existe um custo para levar o petróleo aos terminais, relacionado ao aluguel e operação de navios-tanque. Porém, muito mais importante que os custos envolvidos, é a necessidade de manter as plataformas com capacidade de armazenamento suficiente para receber a produção diária de seus poços, condição que deve ser garantida por operações de alívio cuidadosamente planejadas.

Ainda segundo Assis e Camponogara (2016), as decisões de logística são divididas em 3 níveis hierárquicos: estratégico, tático e operacional. As decisões estratégicas são planejadas considerando o longo prazo, normalmente os próximos

anos, e envolvem investimentos, como o tamanho e composição da frota. As decisões táticas consideram o médio prazo, que engloba os próximos meses, e são equivalentes ao roteamento e programação dos navios. Finalmente o planejamento operacional se ocupa do curto prazo, próximos dias e semanas, e são tomadas as decisões de produtos e quantidades que serão carregados e descarregados em cada viagem.

Rodrigues et al. (2017) estudam um problema de roteirização para navios de transporte de petróleo das plataformas para os terminais. Utilizam modelo de programação inteira mista e uma heurística para tentar representar os principais elementos do sistema real, porém houve uma dificuldade em encontrar a solução exata, por se tratar de um problema muito grande e complexo. No modelo estudado as variáveis consideradas são número de navios, pontos operacionais (plataformas e terminais), conjunto de plataformas que apresentam posicionamento dinâmico, conjunto de navios que apresentam posicionamento dinâmico, restrição de operação dos terminais, velocidade e capacidade dos navios, distância entre os pontos, tamanho do lote, consumo de combustível dos navios, custos de atracação, janela de tempo.

Meza et al. (2015) focaram na construção de um modelo matemático para dimensionamento da frota e definição das rotas dos navios que garanta a redução nos tempos de percurso e o escoamento da produção. Caracterizaram o problema como Roteirização de Veículos com Janela de Tempo. Os autores reforçam que o ideal seria as plataformas operarem com o menor nível de estoque possível, evitando as perdas por custo de oportunidade. Para isto seria necessária a realização de *offloadings* com maior frequência e o roteamento poderia contribuir para este fim. Na construção do modelo foram considerados os tipos de navios disponíveis para os alívios, classificados de acordo com a capacidade; a localização das plataformas e terminais; prazo máximo para realização do alívio, de acordo com a capacidade de cada plataforma; prazo mínimo para realização do alívio, de acordo com o volume mínimo para *offloading*; tempos de operação e finalmente as penalizações caso algum item não seja cumprido.

Jiang et al. (2018) reforçam que o modelo tradicional de transporte ponto a ponto está mudando gradualmente para um modelo multiponto e transporte cooperativo, assim elaboraram um modelo de otimização para planejamento de frota de navios e *scheduling* de alívios nos FPSOs. Os autores dizem que é

necessário determinar o tipo e o número de navios que farão parte da frota baseado na demanda das plataformas e propor uma sequência de atracação destes navios, alocando melhor os recursos das empresas e reduzindo os custos com perdas de produção. Neste artigo, o problema é considerado um problema de roteirização de veículos com restrições severas de janela de tempo. As seguintes considerações são feitas: uma viagem do navio se refere ao período que se inicia no porto, segue para operação de alívio nas plataformas e retorna para um porto para descarga; cada FPSO só pode fazer alívio com um navio, porém um navio pode amarrar sucessivamente em vários FPSOs; todo estoque de óleo da plataforma é aliviado no *offloading*; o tempo de operação de cada navio em uma respectiva plataforma é sempre o mesmo. Um modelo de programação inteira mista visando minimizar o custo total de transporte é proposto e são realizados experimentos numéricos. Os resultados mostraram que o modelo e o algoritmo propostos podem resolver efetivamente o problema.

Camponogara e Plucenio (2014) também apresentam uma formulação de programação linear inteira mista (MILP) para o problema de *scheduling* dos navios-tanque. O modelo tem por objetivo servir como uma ferramenta de suporte à decisão para guiar os engenheiros nas operações diárias. As restrições utilizadas foram capacidade dos navios, tancagem e produção diária das plataformas, estoque mínimo das plataformas, lote mínimo a ser aliviado, entre outras. O óleo que fica estocado na plataforma pode ser considerado como capital parado para a empresa, por outro lado existe o custo de transporte desse óleo, relacionado ao afretamento e operação dos navios. Porém, mais importante que a otimização do transporte, é a necessidade de alívio das plataformas, o que permite a continuidade da produção de petróleo. A estratégia de otimização define as janelas de tempo para operação, mas somente as decisões do primeiro dia são implementadas e o algoritmo é rodado novamente. Uma família de desigualdades válidas é proposta para fortalecer a formulação do MILP e reduzir o tempo de solução. Os resultados computacionais também são relatados sobre a aplicação do modelo proposto em conjunto com uma estratégia de horizonte rolante.

Destes artigos foi possível identificar as variáveis que poderiam ser utilizadas como variáveis independentes no modelo de regressão dinâmica e que, juntamente com a experiência dos analistas de logística, poderão ser utilizadas nas equações de previsão do atendimento à demanda de alívios.

Durante a pesquisa bibliográfica, não foi encontrado nenhum estudo utilizando o método de regressão dinâmica para previsão de alívios em plataformas. O presente trabalho busca correlacionar as variáveis presentes no dia a dia da programação de alívios com o nível de serviço logístico, promovendo um modelo estatístico para avaliar e prever como será o atendimento à demanda de alívio das plataformas nos próximos meses. Com esse modelo será possível entender como cada uma das variáveis influencia na qualidade da logística de alívios e utilizá-lo como ferramenta de decisão para os próximos meses.

3.2.

Utilização de métodos de previsão na indústria de óleo e gás

Foram identificados vários trabalhos na indústria do petróleo que utilizaram o método de regressão dinâmica para realizar previsões de preço, demanda, estoque, entre outros. Serão apresentados a seguir alguns trabalhos mais relevantes.

Zanini (2000) desenvolveu um modelo para previsão da demanda mensal de gasolina automotiva no Brasil. O autor enfatiza que, no cenário competitivo da indústria do petróleo, há a necessidade de projeções confiáveis da demanda de combustíveis, a fim de fornecer subsídios para planejamento e gestão tanto por parte das empresas quanto por parte do órgão regulador. O trabalho se inicia com um modelo autorregressivo, considerando a sazonalidade da demanda. Na sequência, é utilizada a estratégia *bottom-up* para construção de um modelo de regressão dinâmica, incluindo no modelo as variáveis independentes de preço e renda, além dos *lags* da própria demanda de gasolina. Por fim, o autor avançou para a formulação com redes neurais, incluindo as não linearidades inerentes a este mercado. O modelo de regressão dinâmica apresentou melhor resultado que o modelo autorregressivo, porém o modelo gerado por redes neurais, reduziu significativamente os erros de previsão.

Bertoloto (2018), em seu trabalho, teve por objetivo verificar o desempenho do método de regressão dinâmica na previsão de frete marítimo de curto prazo em uma rota específica de exportação de petróleo. Ele ressalta que o transporte marítimo é um componente fundamental na cadeia de petróleo, integrando fornecedores e clientes que se localizam em regiões geográficas distintas, assim, o valor do frete possui grande impacto no comércio internacional do petróleo e seus derivados. No trabalho, o autor fez uma comparação entre o método de regressão

dinâmica com os modelos tradicionais de amortecimento exponencial e ARIMA e propôs alguns cenários para avaliar os efeitos das variáveis explicativas no frete marítimo. O modelo obtido por regressão dinâmica apresentou desempenho melhor na previsão do que o modelo vigente na empresa em estudo.

Ferrer (2018) propôs um modelo para verificar a dependência entre a estadia dos navios em um terminal aquaviário e outras variáveis da cadeia de suprimento de petróleo com o objetivo de reduzir os custos de transporte marítimo da empresa em estudo. As variáveis escolhidas pelo método *bottom-up* para serem incluídas no modelo foram o estoque total de petróleo da empresa, o refino total, o estoque de petróleo dos terminais e refinarias e a quantidade de navios aguardando atracação no tempo $t-1$. Foi constatado, que o aumento no estoque total de petróleo causa um aumento na estadia dos navios, que representa um custo 11% maior que o custo financeiro de estoque.

3.3. Regressão dinâmica

Segundo Chatfield (2000), uma série temporal é uma coleção de observações feitas sequencialmente no tempo e um modelo de série temporal fornece previsões de futuras observações, que podem ser verificadas frente às observações atuais. Se Z_t representa o valor da variável Z no instante de tempo t , a série temporal é representada por Z_1, Z_2, \dots, Z_n , onde n é o tamanho da série ou o número de observações da série.

Box et al. (2015) explicita que numa série temporal discreta, os dados são coletados em intervalos iguais de tempo. Além disso, uma característica especial na série temporal é que observações adjacentes são dependentes e a análise deve considerar a ordem em que foram coletadas. A análise das séries temporais se baseia nessa dependência. Para as séries temporais discretas, as periodizações mais utilizadas são diariamente, mensalmente ou anualmente.

Para Chatfield (2000), as duas principais fontes de variação nas séries temporais são tendência e sazonalidade, e também podem ocorrer variações cíclicas e flutuações irregulares.

Os métodos para obtenção dos modelos de previsão podem ser classificados em:

- Métodos univariados: dependem somente dos valores de uma única série temporal;

- Métodos multivariados: a previsão de uma variável depende dos valores de uma ou mais séries temporais, chamadas variáveis exploratórias ou independentes.

Segundo Box et al. (2015) métodos de análise para séries temporais multivariáveis envolvem o estudo da dinâmica das relações entre várias séries temporais, desenvolvendo modelos estatísticos que melhor descrevem essas inter-relações.

Este trabalho tem como um de seus objetivos a avaliação de como as variáveis do dia a dia do programador de alívios das plataformas impactam na quantidade de alívios críticos de uma empresa de petróleo. O tipo de modelo que permite esta avaliação é obtido através dos métodos de previsão multivariados (causais), que possibilitam uma análise da correlação entre as variáveis dependente e independentes.

Um modelo que apresenta a correlação adequada entre as variáveis torna-se uma importante ferramenta de análise para utilização, tanto no planejamento diário de alívios, quanto para decisões estratégicas empresariais.

Para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes pode ser utilizado o método da regressão dinâmica, originalmente proposto por D. Cochrane e G. H. Orcutt em 1949. Neste modelo, há uma combinação entre a dinâmica das séries temporais e o efeito das variáveis explicativas, assim a variável dependente pode ser representada por seus valores defasados no tempo e pelos valores atuais ou defasados das variáveis causais. Os modelos também podem utilizar variáveis de intervenção, ou variáveis *dummy*, que servem para considerar situações atípicas, como variações abruptas na demanda mensal de algum produto ou alguma intervenção realizada por um período de tempo na série estudada.

Para estimação dos parâmetros do modelo de regressão dinâmica, é utilizado o método dos mínimos quadrados e envolve um processo iterativo com vários estágios.

Segundo Zanini (2000), os modelos de regressão dinâmica podem ser descritos pela equação:

$$\varphi(B)Y_t = \beta x_t + \varepsilon_t \quad (3.1)$$

Onde:

Y_t = variável dependente no instante t

β = vetor de coeficientes das variáveis independentes que será estimado por mínimos quadrados

x_t = vetor de variáveis independentes no instante t

ε_t = ruído aleatório associado ao modelo, supõe-se independentes e identicamente distribuídos, com distribuição $N(0, \sigma^2)$

$\varphi(B)$ = polinômio autoregressivo de ordem p , isto é: $\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$

B = operador de atraso

Essa estrutura do modelo de regressão permite considerar x_t variáveis causais e também suas defasagens. O polinômio $\varphi(B)$ traz ao modelo uma grande flexibilidade, mas aumenta a dificuldade na busca do modelo mais adequado. Quando $\varphi(B) = 1$, não existem defasagens na variável dependente e o modelo se torna mais simples, pois resta apenas a influência das variáveis causais. Já quando $\varphi(B) \neq 1$, o modelo fica bastante complexo.

Este modelo apresentado pode ser considerado um caso particular dos modelos de Cochrane e Orcutt (1949) generalizados, dado por:

$$\varphi(B)Y_t = \beta x_t + w_t \quad (3.2)$$

$$R(B)w_t = \varepsilon_t \quad (3.3)$$

Onde $R(B)$ é um polinômio autorregressivo.

Este modelo pode ser reescrito com uma única equação:

$$R(B) \cdot [\varphi(B)Y_t - \beta x_t] = \varepsilon_t \quad (3.4)$$

Pode-se notar que este modelo introduz defasagens tanto na variável dependente quanto nas causais e também que a relação de causalidade entre Y_t e x_t não é afetada pela inclusão do polinômio autorregressivo $R(B)$. A equação pode ser escrita em termos de novas variáveis:

$$\begin{aligned} Y_t^* &= R(B)Y_t \\ x_t^* &= R(B)x_t \\ \varphi(B)Y_t^* &= \beta x_t^* + \varepsilon_t \end{aligned} \quad (3.5)$$

Assim, o modelo de regressão generalizado por Cochrane e Orcutt (1949) reduz-se ao modelo de regressão dinâmica usual. No modelo original, há o fator comum $R(B) = 1 - \alpha B$, então a equação fica assim modificada:

$$\varphi(B) \cdot [Y_t - \alpha Y_{t-1}] = \beta [x_t - \alpha x_{t-1}] + \varepsilon_t \quad (3.6)$$

Para utilização deste modelo, o procedimento de estimação é sequencial. Partindo-se de $\alpha = 0$, pode-se estimar β e $\varphi(B)$ por mínimos quadrados ordinários. Pode-se então encontrar o estimador $R(B)$ através da equação 3.3. O polinômio estimado é então utilizado para transformar Y_t e x_t e reestimar β e $\varphi(B)$. O processo é repetido até a convergência dos parâmetros.

Para Montgomery (2008), o analista normalmente tem uma boa noção sobre a forma do modelo que deseja ajustar, porém pode haver incerteza em relação à estrutura deste modelo. Ele pode não saber se todas as variáveis são realmente necessárias. Assim, esse tipo de modelagem envolve uma grande lista de variáveis candidatas a serem utilizadas e o objetivo do analista é ajustar o modelo de regressão com o melhor conjunto de variáveis. Geralmente, os métodos para selecionar o conjunto de variáveis que será utilizado são do tipo passo-a-passo. Eles incorporam ou removem uma variável a cada passo. No processo *bottom-up*, o modelo começa sem nenhuma variável dependente e sequencialmente insere uma variável por vez. O processo continua até que não existam mais variáveis qualificadas para entrar na equação.

No processo *top-down*, o modelo inicial inclui todas as variáveis candidatas e então uma por vez é retirada até a equação final ser encontrada. As variáveis vão sendo removidas até todos os termos da equação remanescentes serem significativos.

Para a regressão dinâmica, além das variáveis independentes, é necessário avaliar a inclusão das defasagens (*lags*) destas variáveis e da variável dependente.

Durante a elaboração do modelo de regressão dinâmica, são realizados testes de hipóteses sobre a dinâmica do modelo. A hipótese nula afirma que o modelo já está corretamente especificado e que não há necessidade de inclusão de outras variáveis ou defasagens. Já a hipótese alternativa representa a inclusão de novos termos. Caso haja significância estatística, a variável ou *lag* que foi testado é adicionado ao modelo. Para a verificação da dinâmica do modelo, são propostos os seguintes testes:

- teste de defasagem da variável dependente: a hipótese alternativa consiste em adicionar a próxima defasagem que ainda não está presente no modelo atual, assim, se o modelo já inclui os *lags* $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p-1}$, o *lag* Y_{t-p} é então testado.

- Teste de defasagem sazonal da variável dependente: a hipótese alternativa consiste em adicionar a variável defasada até o primeiro *lag* sazonal ainda não presente no modelo atual.

- Teste da sequência de defasagens da variável dependente: a hipótese alternativa adiciona todos os *lags* que ainda não estão no modelo atual.

- teste de defasagem dos resíduos: a hipótese alternativa considera a adição do primeiro termo defasado ε_{t-p} que ainda não foi incluído no modelo atual.

- Teste de defasagem sazonal dos resíduos: a hipótese alternativa adiciona o primeiro *lag* sazonal do resíduo que ainda não foi incorporado no modelo atual.

- Teste da sequência de defasagens dos resíduos: na hipótese alternativa adiciona-se uma sequência de resíduos defasados que ainda não estão presentes no modelo.

Também são feitos os seguintes testes para inclusão das variáveis causais:

- Teste das variáveis causais excluídas: verifica-se a necessidade de inclusão de cada uma das variáveis independentes previamente escolhidas que ainda não estão presentes no modelo.

- teste de tendência temporal: inclusão da variável $X_t = t$ no modelo. Esta variável é útil quando a série não é estacionária.

- Teste de defasagem das variáveis causais: a hipótese alternativa inclui um *lag* adicional das variáveis causais que já estão no modelo atual.

- Teste para a presença de funções não lineares das variáveis causais: inclui o quadrado de cada variável independente já presente no modelo.

- Teste do fator comum: este teste só deve ser realizado quando o modelo inclui erros estruturados. Na hipótese alternativa, a autorregressão dos erros é eliminada e todos os *lags* das variáveis depende e independentes são adicionados ao modelo.

Para Chatfield (2000), a verificação do modelo deve avaliar se ele é consistente com o conhecimento prévio e com as propriedades dos dados. Assim, mesmo após a avaliação da significância dos termos da equação, ainda é necessário

verificar se os coeficientes estimados são coerentes e essa avaliação depende do conhecimento do analista sobre os dados.

3.4. Análise dos erros

Nos modelos de regressão, os erros possuem algumas características importantes, como média zero, variância constante, distribuição Normal e independência.

Segundo Montgomery (2008), o gráfico dos resíduos é a primeira validação do modelo. Se houver uma variância constante, o gráfico deve mostrar os resíduos espalhados de forma randômica ao redor de zero.

Para Chatfield (2000), a média dos resíduos indica o viés da previsão. A média deve ser próxima de zero para uma previsão sem viés. Um resíduo individual muito grande pode indicar uma observação *outlier*, que deve ser verificada e, se necessário, ajustada.

Durante o processo de construção do modelo de regressão dinâmica, deve-se examinar o gráfico das autocorrelações dos resíduos, a fim de verificar se o modelo atual é adequado. A existência de autocorrelações significantes nos resíduos pode indicar a necessidade de incluir mais *lags* da variável dependente ou das variáveis independentes já presentes no modelo, ou então novas variáveis causais. É importante notar que, o fato dos resíduos apresentarem autocorrelações significantes, algum tipo de estrutura presente na série Y_t não está sendo representada no modelo atual.

Neste trabalho foi utilizado como parâmetro para avaliação do modelo o MAPE (Mean Absolute Percentage Error ou Erro Absoluto Médio Percentual), que representa o erro percentual, e é definido pela equação 3.7.

$$MAPE = \left(\frac{1}{n} \sum \frac{|Y_t - F_t|}{|Y_t|} \right) * 100 \quad (3.7)$$

Onde:

Y_t = variável dependente no instante t

F_t = previsão da variável dependente no instante t

n = número de observações

Segundo Hyndman e Koehler (2006), os erros percentuais têm a vantagem de serem independentes de escala e, portanto, são frequentemente usados para comparar o desempenho de previsão em diferentes conjuntos de dados.

4 Modelagem

Neste capítulo serão apresentadas as variáveis utilizadas para a modelagem da regressão dinâmica e o *software* escolhido para elaboração do modelo.

4.1. Variáveis dependentes

Como o objetivo deste estudo foi prever o nível de serviço logístico para escoamento da produção de petróleo para os próximos meses, foi feito um minucioso levantamento de todos os alívios realizados mensalmente de jan/16 a dez/19 e neste período a média foi de aproximadamente 100 alívios por mês. Posteriormente foi feita uma classificação de quais deles se encaixavam na categoria de alívio crítico. Com esses dados, foi possível calcular o percentual de alívios críticos com menos de 48 horas para o TOP e o percentual de alívios críticos com menos de 24 horas para o TOP. Esses dados são mostrados nos gráficos a seguir.




Figura 06 - Percentual de alívios críticos com menos de 48 horas para o TOP. Fonte: Elaboração própria.

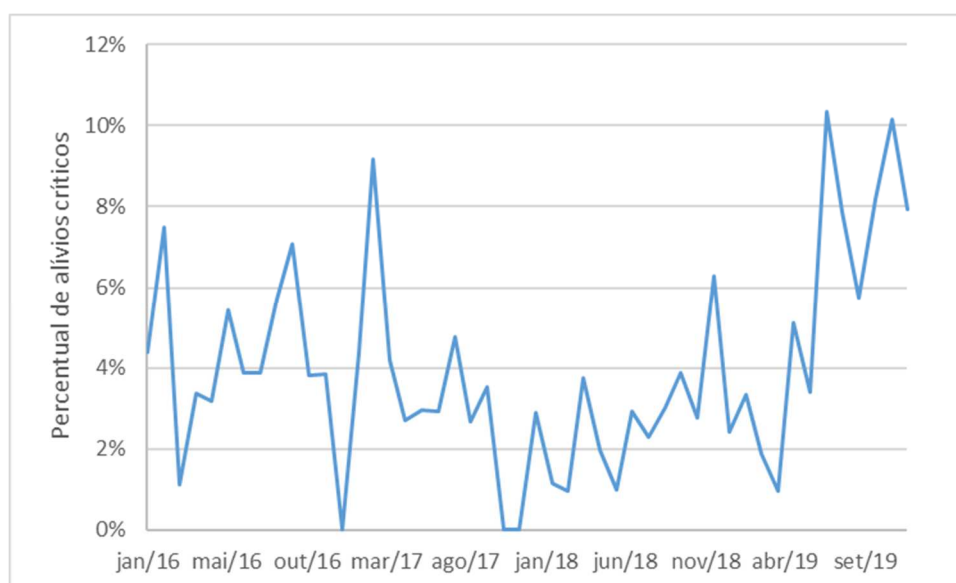


Figura 07 - Percentual de alívios críticos com menos de 24 horas para o TOP. Fonte: Elaboração própria.

Como pode ser visto, as duas curvas não seguem a mesma tendência e devem ser analisadas separadamente. Em uma primeira análise, não é possível identificar uma sazonalidade, porém há uma tendência de aumento no final do período analisado.

Avaliando a série histórica das variáveis, o percentual médio de alívios críticos com menos de 48 horas para o TOP foi de aproximadamente 15% e a média do percentual de alívios críticos com menos de 24 horas foi de aproximadamente 5%. Considerando que os alívios com menos de 24 horas para o TOP são os mais prováveis de incorrerem em perda de produção e que a produção brasileira de petróleo em 2018 foi de 2.683 mil barris/dia (IBP), a perda de 5% da produção seria equivalente a perda de US\$9.566.000,00 por dia. Este potencial de perda de receita é muito significativo, dessa forma a empresa estudada investe muito recurso e tempo para atuar na gestão da logística de alívios, com objetivo de reduzir o percentual de alívios críticos e buscar o zero absoluto de perda de produção.

4.2. Variáveis independentes

A partir da revisão da literatura e do conhecimento dos analistas envolvidos no processo de programação dos alívios das plataformas, foram identificadas todas

as variáveis independentes que poderiam ser disponibilizadas para compor o modelo.

A primeira variável independente identificada é o número de navios. Ela considera todos os navios-tanque disponíveis na frota da empresa naquele mês.

Em seguida, verificou-se a necessidade de desconsiderar o período em que esses navios estavam indisponíveis para *offloading*, seja por manutenção planejada ou emergencial, descontando assim as horas em *off-hire*. Esse processo resultou na variável número de horas disponíveis dos navios no mês, medida em mil horas.

Sabendo quais os alívios foram realizados em cada mês, pode-se contabilizar o número total de plataformas que foram aliviadas naquele mês.

Uma variável muito importante foi a produção mensal média de petróleo, medida em mil m³/d. Essa variável engloba a produção de todas as plataformas nas quais a empresa é responsável pela logística de alívios.

Também se mostrou importante levantar o lote médio mensal. Essa variável representa a média do tamanho de todos os lotes aliviados no mês em todas as plataformas, medido em mil m³.

Outra variável disponibilizada foi o refino médio mensal. Ela engloba a média de petróleo processado por dia nas refinarias da empresa, em mil m³/d.

Além do refino, outro destino para o petróleo são as exportações. Assim, utilizou-se como variável a média diária de exportações realizadas no mês, medida em mil m³/d.

O estoque médio de petróleo do mês também foi disponibilizado como variável independente. Ele representa o estoque em todos os pontos operados pela empresa, incluindo terminais, refinarias, plataformas e navios e é medido em mil m³/d.

Também foi identificada a necessidade de inclusão de uma variável *dummy*, que representa a previsão do tempo no mês. Quando há condições de mar com ondas acima de 3,5m e ventos com velocidade acima de 40 nós, há uma dificuldade de amarração do navio aliviador à plataforma, o que atrasa os *offloadings* e pode causar um alívio crítico. Para elaboração desta variável, foi realizado um levantamento histórico com a área responsável pelo monitoramento ambiental da empresa com os dados de jan/16 a dez/19. A partir destes dados, foi possível identificar que os meses de maio, julho, agosto e setembro apresentam maior quantidade de dias com condições de mar adversas e são chamados meses de mau tempo. Assim, durante a

modelagem, nos meses de mau tempo foi utilizado valor um para variável *dummy* e nos outros meses foi utilizado valor zero.

4.3. Software utilizado

Para modelagem, foi utilizado a versão acadêmica do *software Forecast Pro for Windows 1.0.0.1 (FPW)*. Com ele foi possível utilizar a técnica *bottom-up*, partindo de um modelo no qual a variável dependente é explicada apenas por uma constante e a cada rodada incluindo uma nova variável. A partir dos testes de hipóteses e do p-valor, este *software* indica quais são as variáveis mais adequadas para integrar o modelo e também quais os *lags*, tanto da variável dependente quando das variáveis independentes devem ser incluídos.

Foi utilizado um *hold-out* dos 3 últimos meses para avaliação do modelo *out-of-sample*.

5 Resultados e Discussões

Para elaboração do modelo de previsão dos alívios críticos, foram utilizados os dados históricos da empresa estudada de 2016 a 2019. Foram feitos dois modelos, um para previsão do percentual de alívios críticos com menos de 48 horas para o TOP e outro para o percentual de alívios críticos com menos de 24 horas para o TOP. As variáveis causais disponibilizadas para a modelagem foram: número de navios, número de horas disponíveis dos navios, número de plataformas, produção média mensal, lote médio mensal, refino médio mensal, exportação média mensal, estoque médio e finalmente uma variável *dummy* de previsão do tempo.

A partir da inserção das variáveis dependente e independentes no FPW, foram feitos inúmeros testes a fim de identificar quais variáveis independentes e quais *lags* seriam os mais adequados para serem incluídos no modelo de previsão de alívios críticos. Os modelos foram feitos com os dados na sua forma original. Poderia ter sido utilizado a metodologia log-log, em que os dados são inseridos na sua forma logarítmica, e assim, o modelo traria informações de elasticidade das variáveis. Porém optou-se pela análise de sensibilidade para avaliação da influência das variáveis independentes na variável dependente.

A cada rodada, foi realizada a verificação dos coeficientes e da significância estatística, bem como a avaliação da distribuição dos erros. Assim, foram definidos os melhores modelos para previsão dos alívios críticos com menos de 48 horas e 24 horas, que serão mostrados a seguir.

5.1. Alívios críticos com menos de 48 horas

O modelo que apresentou melhor resultado para previsão dos alívios críticos com menos de 48 horas foi:

$$aliv_{48}_t = -63,128174 + 0,006655est_{med}_t + 3,212322prev_{temp}_t + 0,134068prod_t \quad (5.1)$$

Onde:

$aliv_{48}_t$ = previsão de percentual de alívios críticos com menos de 48 horas no mês t ;

est_{med}_t = estoque médio de petróleo no mês t (mil m^3/d);

$prev_{temp}_t$ = variável *dummy*, nos meses de maio, julho, agosto ou setembro deve-se utilizar o valor 1, nos outros meses utilizar 0;

$prod_t$ = produção de petróleo no mês t (mil m^3/d).

Na análise dos coeficientes, pode-se notar que quanto maior a produção de petróleo, maior será o percentual de alívios críticos com menos de 48 horas. Essa correlação é adequada, visto que a produção maior resulta em uma data de TOP da plataforma antecipada, o que gera a necessidade de os navios chegarem mais cedo.

O aumento no estoque médio de petróleo da empresa também eleva o percentual de alívios críticos com menos de 48h, pois aumenta o tempo de giro dos navios, o que atrasa a chegada dos navios nas plataformas.

A variável *dummy* de previsão do tempo também possui um impacto significativo na previsão de alívios críticos com menos de 48 horas, visto que nos meses em que o mau tempo é mais acentuado, ocorrem atrasos tanto no alívio das plataformas, quanto na descarga dos navios nos terminais, prejudicando o atendimento aos *offloadings*.

O fato de a constante do modelo possuir um sinal negativo, não desmerece sua utilização, visto que as outras variáveis nunca atingirão um valor tão baixo a ponto da previsão de alívios críticos se tornar negativa, o que seria uma falha para utilização do modelo.

As defasagens, tanto da variável dependente quanto das variáveis causais não tiveram significância para inclusão no modelo. Também não houve indicação de utilização das outras variáveis independentes.

Na tabela 02 é apresentada a significância das variáveis introduzidas no modelo. Esses números são resultados do teste de hipótese, validando a hipótese nula e descartando a hipótese alternativa, ou seja, o as variáveis escolhidas de fato são significantes, dentro do nível de confiança de 95%, para o modelo de previsão dos alívios críticos com menos de 48 horas.

Tabela 02 - Significância das variáveis do modelo.

Variável	Significância
<i>est_med_t</i>	0,999775
<i>prev_temp_t</i>	0,973512
<i>prod_t</i>	0,992906
<i>constante</i>	0,999958

Fonte: Elaboração própria.

Para o modelo, há um erro aproximado de 30% nas previsões em relação aos dados reais. Já para os dados *out-of-sample*, o MAPE acumulado é de 22,9%. A tabela 03 mostra o desempenho do modelo para os dados *out-of-sample*.

Tabela 03 - Desempenho do modelo *out-of-sample*

Horizonte	Número de previsões	MAPE	MAPE Acumulado
1	3	25,1%	25,1%
2	2	16,3%	21,6%
3	1	29,5%	22,9%

Fonte: Elaboração própria.

A figura 08 mostra a curva com os dados reais de percentual de alívios críticos com menos de 48 horas acrescida da curva de tendência do modelo proposto (linha vermelha). Pode-se observar que o modelo apresentou um ajuste adequado para os dados apresentados e que os dados *out-of-sample* ficaram entre os valores mínimo e o máximo previstos pelo modelo.

O comportamento esperado para os dados *out-of-sample* seria de aumento no MAPE ao longo do horizonte, porém essa tendência não é observada nos dados da Tabela 04, que mostra o MAPE do segundo ponto menor que o MAPE do primeiro ponto. Isto é explicado pela Figura 08, onde a previsão do modelo para o segundo ponto *out-of-sample* é muito mais assertiva que a previsão do primeiro ponto.




Figura 08 - Dados originais de previsão do percentual de alvíos críticos com menos de 48 horas acrescidos da curva de previsão do modelo desenvolvido. Fonte: Elaboração própria.

A figura 09 mostra a distribuição dos erros. Pode-se perceber que os erros variam de forma randômica ao redor de zero e todos os valores dentro da faixa aceitável, que indica uma validação do modelo e ausência de viés na modelagem.




Figura 09 - Distribuição dos erros do modelo de previsão para alvíos críticos com menos de 48 horas. Fonte: Elaboração própria.

5.1.1. Análise de sensibilidade dos alívios críticos com menos de 48 horas

O modelo obtido para previsão do percentual de alívios com menos de 48 horas para o TOP mostra-se uma importante ferramenta para os analistas que fazem a gestão da logística de alívios. Utilizando o modelo é possível a elaboração de cenários para avaliação dos impactos na variação do estoque mensal e da produção de petróleo. A figura 10 mostra a análise de sensibilidade do percentual de alívios críticos com o aumento de até 10% nas variáveis causais.




Figura 10 - Análise de sensibilidade do percentual de alívios críticos com menos de 48 horas para o TOP. Fonte: Elaboração própria.

Pela análise de sensibilidade, pode-se concluir que um aumento em 5% tanto na produção de petróleo quanto no estoque médio mensal resulta em um aumento de aproximadamente 2% nos alívios críticos com menos de 48 horas para o TOP, aumentando as chances de perda de produção de petróleo.

Este resultado é muito importante para uma gestão logística, pois é possível balancear as duas variáveis de forma a evitar o aumento de alívios críticos. Caso haja previsão de aumento de produção de petróleo para os próximos meses, se faz necessário maior atenção na gestão de estoques, antecipando sua redução a fim de gerenciar os alívios críticos em um patamar mais baixo.

De todas as variáveis disponibilizadas para compor o modelo, somente a produção de petróleo média, o estoque médio e a previsão do tempo mostraram influência no percentual de alívios críticos com menos de 48 horas para o TOP. Sabendo-se que a previsão do tempo não é gerenciável e que a produção de petróleo é sempre maximizada, a gestão estratégica deve ser realizada na meta de estoque médio da empresa. Dessa forma, a gestão de estoques se mostra a principal ferramenta de planejamento logístico para redução de alívios críticos, com consequente minimização de perdas de produção.

De posse desse modelo, a empresa estudada agora possui uma ferramenta matemática que pode ser usada para tomada de decisão, contrabalanceando com a experiência dos programadores e com fatores não-gerenciáveis. A utilização de variáveis operacionais dentro de uma ferramenta de gestão resulta em decisões mais assertivas, o que pode melhorar os indicadores econômico-financeiros da empresa.

5.2. Alívios críticos com menos de 24 horas

O modelo que apresentou melhor resultado para previsão dos alívios críticos com menos de 24 horas foi:

$$aliv_{24_t} = 0,003364est_{med_t} - 0,042147exp_t - 0,143534lote_t \quad (5.2)$$

Onde:

$aliv_{24_t}$ = previsão de percentual de alívios críticos com menos de 24 horas no mês t;

est_{med_t} = estoque médio de petróleo no mês t (mil m³/d);

exp_t = exportação média de petróleo no mês t (mil m³/d);

$lote_t$ = lote médio no mês t (mil m³).

Na análise dos coeficientes, pode-se notar que, quanto maior o estoque médio de petróleo, maior será o percentual de alívios críticos com menos de 24 horas, pois ocorre o aumento no tempo de giro dos navios, o que atrasa a chegada dos navios nas plataformas.

A quantidade de petróleo exportado no mês reduz o percentual de alívios críticos com menos de 24h, pois faz uma desova de petróleo no sistema como um todo e reduz o tempo de giro dos navios, melhorando o atendimento às plataformas.

Quanto maior o tamanho do lote, menor o percentual de alívios críticos com menos de 24 horas, pois há uma melhor eficiência no transporte proporcionando otimização no giro dos navios e conseqüentemente um melhor atendimento ao TOP das plataformas.

As defasagens, tanto da variável dependente quanto das variáveis causais não tiveram significância para inclusão no modelo. Houve indicação de utilização também do número de horas disponíveis dos navios como variável independente, porém a análise do coeficiente mostrou que a relação entre as variáveis estava invertida, ou seja, o aumento no número de horas de navios estava gerando um aumento no percentual de alívios críticos, o que é ao contrário da realidade. Assim, essa variável foi descartada no modelo.

Na tabela 04 é apresentada a significância das variáveis introduzidas no modelo. Da mesma forma que no modelo para alívios críticos com menos de 48 horas, esses números validam as variáveis escolhidas, dentro do nível de confiança de 95%, para o modelo de previsão dos alívios críticos com menos de 24 horas.

Tabela 04 - Significância das variáveis do modelo

Variável	Significância
<i>est_med_t</i>	0,999988
<i>exp_t</i>	0,969590
<i>lote_t</i>	0,999761

Fonte: Elaboração própria.

O MAPE deste modelo ficou em aproximadamente 48% e pode parecer muito alto, porém quando os dados *out-of-sample* são analisados, pode-se perceber que o erro cai para 13,3%. Assim, pode-se considerar que este modelo é adequado para a previsão dos próximos meses. A tabela 05 mostra este desempenho do modelo *out-of-sample*.

Tabela 05 - Desempenho do modelo *out-of-sample*

Horizonte	Número de previsões	MAPE	MAPE Acumulado
1	3	16,3%	16,3%
2	2	11,7%	14,4%
3	1	7,5%	13,3%

Fonte: Elaboração própria.

A figura 11 mostra a curva com os dados reais de percentual de alívios críticos com menos de 24 horas acrescida da curva de tendência do modelo proposto (linha vermelha). A análise do gráfico mostra a adequação do modelo para os dados apresentados e que os dados *out-of-sample* ficaram entre os valores mínimo e o máximo previstos pelo modelo.




Figura 11 - Dados originais de previsão do percentual de alívios críticos com menos de 24 horas acrescidos da curva de previsão do modelo desenvolvido. Fonte: Elaboração própria.

A figura 12 mostra a distribuição dos erros. Pode-se perceber que os erros variam de forma randômica ao redor de zero e todos os valores dentro da faixa aceitável, que indica uma validação do modelo e ausência de viés na modelagem.




Figura 12 - distribuição dos erros do modelo de previsão para alívios críticos com menos de 24 horas. Fonte: Elaboração própria.

5.2.1. Análise de sensibilidade dos alívios críticos com menos de 24 horas

O modelo de previsão do percentual de alívios críticos com menos de 24 horas para o TOP utilizou como variáveis causais o estoque médio, o lote médio e as exportações diárias médias. A partir dele, foi possível construir uma análise de sensibilidade para avaliar como cada uma dessas variáveis impacta nos alívios críticos e esta análise é mostrada na figura 13.

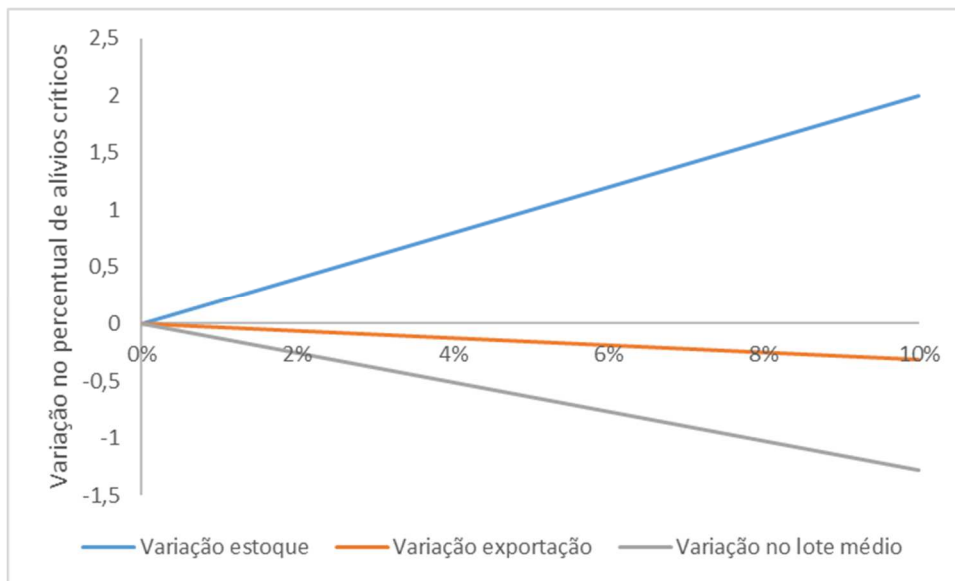


Figura 13 - Análise de sensibilidade do percentual de alívios críticos com menos de 24 horas para o TOP. Fonte: Elaboração própria.

A partir da análise de sensibilidade pode-se visualizar que um aumento de 10% na exportação média diária causa uma redução muito pequena, da ordem de 0,3%, no percentual de alívios críticos com menos de 24 horas para o TOP. Assim, esta variável não deve ser tratada como prioritária nas ações que objetivam a redução dos alívios críticos.

O aumento de 5% no estoque médio mensal gera um aumento da ordem de 1% nos alívios críticos com menos de 24 horas. Assim, a política de estoques é uma ferramenta muito importante para a gestão dos alívios críticos. Se torna necessário buscar um estoque médio equilibrado, de modo a minimizar as perdas de produção.

O aumento de 10% no lote médio resulta na redução de 1,3% nos alívios críticos com menos de 24 horas. Essa informação é muito importante para os analistas que fazem a programação dos alívios, pois, além das restrições físicas de cada plataforma, o tamanho do lote pode ser decidido pelo programador. Assim, conhecendo esse impacto, o programador deve sempre buscar maximizar o tamanho dos lotes, que tanto aumenta a otimização logística quanto reduz a probabilidade de perda de produção.

O modelo para previsão do percentual de alívios críticos com menos de 24 horas se mostrou mais adequado para o uso nas decisões operacionais em conjunto com as decisões estratégicas de estoque.

Para a empresa estudada, este modelo pode ser usado como ferramenta para previsão dos alívios críticos dos próximos meses e também como base para a meta dessas variáveis, de modo a buscar um balanço entre elas e minimizar o percentual de alívios críticos com menos de 24 horas para o TOP. Além disso, pode ser utilizado para melhoria da programação dos *offloadings*, gerando ganhos financeiros através da minimização da perda de produção.

6 Conclusões e Recomendações

Neste trabalho foram gerados dois modelos para previsão do percentual de alívios críticos para a empresa estudada, um para alívios críticos até 48 horas antes do TOP e outro para os alívios críticos até 24 horas antes do TOP. Da mesma forma que a análise preliminar dos dados históricos, os modelos gerados mostraram que não há correlação entre eles e que as variáveis utilizadas como causais são diferentes.

Atualmente, a empresa estudada não possui nenhum modelo para a previsão dos alívios críticos. Assim, os dois modelos gerados neste trabalho podem ser utilizados como uma ferramenta para aumento de eficiência logística, possibilitando redução do risco de perda de produção por falta de espaço nas plataformas. A parada de uma plataforma típica representa uma perda financeira da ordem de 10 milhões de dólares por dia. Assim, um modelo que utiliza variáveis operacionais e estratégicas da própria empresa representa um ganho para o processo de programação dos alívios, gerando resultado financeiro positivo.

O modelo para previsão do percentual de alívios críticos com menos de 48 horas para o TOP utilizou como variáveis independentes a produção de petróleo diária média, o estoque médio e a previsão do tempo. Estas variáveis, quando incrementadas, geram aumento dos alívios críticos.

A partir da análise de sensibilidade, pode-se concluir que a gestão de estoques é muito importante para a manutenção dos alívios críticos com menos de 48 horas para o TOP em patamares gerenciáveis. Assim, as decisões estratégicas de estoque meta impactam diretamente na redução da probabilidade de perda de produção de petróleo, maximizando o faturamento da empresa estudada.

As variáveis que integraram o modelo de previsão do percentual de alívios críticos com menos de 24 horas para o TOP foram: estoque médio, exportações diárias médias e lote médio. Neste modelo, ao aumento do estoque médio gera um aumento nos alívios críticos. Por outro lado, o aumento nas exportações e no tamanho do lote gera uma redução nos alívios críticos.

A variação na média diária de exportações resultou em pequena redução nos alívios críticos com menos de 24 horas. Assim, esta variável não deve ser prioridade nas decisões estratégicas ou operacionais para redução nos alívios críticos.

O aumento no tamanho do lote médio causou redução significativa nos alívios críticos com menos de 24 horas para o TOP. Como essa variável faz parte das decisões operacionais do programador, a maximização do tamanho dos lotes deve ser prioridade no dia a dia, com objetivo de reduzir os alívios críticos.

Da mesma forma que para os alívios com menos de 48 horas, o estoque médio tem grande importância na redução dos alívios críticos com menos de 24 horas para o TOP. Assim, esta variável deve ser constantemente monitorada para evitar perdas de produção de petróleo. O fato desta variável estar presente nos dois modelos, reforça a importância da gestão de estoques nas decisões estratégicas da empresa estudada.

Estes modelos gerados podem ser utilizados pela empresa estudada para a previsão de nível de serviço logístico baseado no atendimento à demanda de *offloading* das plataformas. Com a projeção dos dados de produção, estoque médio, exportações e lote médio, além da previsão do tempo, é possível prever o percentual de alívios críticos para os próximos meses.

Considerando a grande importância que a gestão de estoques mostrou na redução dos alívios críticos, uma sugestão para os próximos trabalhos é encontrar o estoque meta mais otimizado para a empresa. Este estoque meta deve ser um balanço entre o estoque mínimo necessário para o atendimento das demandas de consumo, refino e exportações, e o máximo para reduzir a quantidade de alívios críticos, com consequente redução do risco de perda de produção de petróleo. Além disso, pode ser estudada a estratégia de distribuição do petróleo dentro da cadeia de estoques que abrange as plataformas produtoras, navios-tanque, tanques dos terminais e das refinarias, buscando o local mais adequado para acúmulo de estoque e redução de custo.

7 Referências Bibliográficas

Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP). Disponível em <<http://www.anp.gov.br>>. Acesso em: 03 de março de 2020.

ASSIS, L. S.; CAMPONOGARA, E. A MILP model for planning the trips of dynamic positioned tankers with variable travel time. **Transportation Research Part E**, v.93, p.372-388, 2016

BERTOLOTO, R. F. **Previsão de fretes de navios petroleiros no mercado spot**. 2018. 69p. Dissertação (Mestrado em Engenharia de Produção) – Pontifícia Universidade Católica do Rio de Janeiro.

BOX, G. E. P. et al. **Time Series Analysis: Forecasting and Control**. 5.ed. New Jersey: Wiley, 2015. 712p.

CAMPOGONARA, E.; PLUCENIO, A. Scheduling dynamically positioned tankers for offshore oil offloading. **International Journal of Production Research**, v.52, n.24, p.7251-7261, 2014.

CHATFIELD, C. **Time-series forecasting**. Boca Raton: Chapman & Hall/CRC, 2000. 265p.

COCHRANE, D.; ORCUTT, G. H. Application of least squares regression to relationships containing auto-correlated error terms. **Journal of American Statistical Association**, v.44, n.245, p.32-61, 1949.

DONG, Y.; VINNEM, J. E.; UTNE, I. B. Improving safety of DP operations: learning from accidents and incidents during offshore loading operations. **EURO Journal on Decision Processes**, v.5, p.5-40, 2017.

Empresa de Pesquisa Energética (EPE). Disponível em <<http://www.epe.gov.br/pt>>. Acesso em: 23 de maio de 2020.

FERRER, P. P. **Influência do estoque de petróleo na duração da estadia de navios petroleiros em um grande terminal aquaviário**. 2018. 72p. Dissertação (Mestrado em Engenharia de Produção) – Pontifícia Universidade Católica do Rio de Janeiro.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v.22, p.679-688, 2006.

Instituto Brasileiro de Petróleo, Gás e Biocombustíveis (IBP). Disponível em <<https://www.ibp.org.br>>. Acesso em: 03 de março de 2020.

JIANG, Z.; CHEN, D.; YANG Z. A synchronous optimization model for multiship shuttle tanker fleet design and scheduling considering hard time window constraint. **Journal of Advanced Transportation**, v.2018, p.1-8, 2018.

LIN, B.; ANKRAH, I.; MANU, S. A. Brazilian energy efficiency and energy substitution: A road to cleaner national energy system. **Journal of Cleaner Production**, v.162, p.1275-1284, 2017.

MENG, H.; KLOUL, L.; RAUZY, A. Production availability analysis of Floating Production Storage and Offloading (FPSO) systems. **Applied Ocean Research**, v.74, p.117-126, 2018.

MEZA, E. B. M. et al. Um modelo matemático para roteamento de navios aliviadores no escoamento da produção de petróleo. **Revista Eletrônica Gestão e Saúde**, v.6, p.955-970, 2015.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**, New Jersey: John Wiley & Sons, 2008. 469p.

PEREIRA JR., A. O. et al. Energy in Brazil: Toward sustainable development? **Energy Policy**, v.36, p.73-83, 2008.

RODRIGUES, V. P. et al. Abordagens de otimização para um problema de roteirização e programação de navios petroleiros. **Gestão & Produção**, v.24, n.4, p. 790-805, 2017.

ZANINI, A. **Redes neurais e regressão dinâmica: um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva no Brasil**. 2000. 85p. Dissertação (Mestrado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro.