

SUPRIMENTOS DE SONDAS: UMA ABORDAGEM DE PROGRAMAÇÃO
ESTOCÁSTICA

Bruno Ferreira Vieira

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

Orientador: Virgílio José Martins Ferreira Filho

Rio de Janeiro
Março de 2014

SUPRIMENTOS DE SONDAS: UMA ABORDAGEM DE PROGRAMAÇÃO
ESTOCÁSTICA

Bruno Ferreira Vieira

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

Examinada:

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

Prof. Edilson Fernandes de Arruda, D.Sc.

Prof^a. Laura Silvia Bahiense da Silva Leite, D.Sc.

Prof. Paulo César Ribas, D.Sc.

Prof. Silvio Hamacher, Dr.

RIO DE JANEIRO, RJ – BRASIL
MARÇO DE 2014

Vieira, Bruno Ferreira

Suprimentos de Sondas: Uma Abordagem de Programação Estocástica/ Bruno Ferreira Vieira. – Rio de Janeiro: UFRJ/ COPPE, 2014.

XII, 107p.: il., 29,7 cm.

Orientador: Virgílio José Martins Ferreira Filho.

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia de Produção, 2014.

Referências Bibliográficas: p. 92-97.

1. Programação Estocástica. 2. Sondas *Offshore*. 3. Logística *Offshore*. I. Ferreira Filho, Virgílio José Martins. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Produção. III. Título

Dedico esse trabalho a minha esposa Camila, a minha filha Shushanaah e a meus pais,
José Gil e Solange.

Agradecimentos

A Deus sempre.

A minha esposa Camila agradeço o incentivo, a compreensão e a ajuda nesse período, sem os quais esse trabalho não seria concluído.

Aos meus pais pelo incentivo constante na busca pelo conhecimento.

Ao professor Virgílio por sua orientação e paciência.

A Felipe Bellini, Luiz Augusto Petrus Levy e aos colegas do CENPES/PDEP/TOOL por todo o apoio para a concretização desse trabalho.

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

SUPRIMENTOS DE SONDAS: UMA ABORDAGEM DE PROGRAMAÇÃO ESTOCÁSTICA

Bruno Ferreira Vieira

Março/2014

Orientador: Virgílio José Martins Ferreira Filho

Programa: Engenharia de Produção

Esse trabalho tem como objetivo usar técnicas de programação estocástica para reduzir os custos logísticos relativos a suprimentos de sondas offshore, considerando que esse assunto é de grande importância para a indústria do petróleo no Brasil. Dado o grande número de poços que precisam ser perfurados para atender o crescimento esperado da produção nacional de petróleo nos próximos dez anos, faz-se importante o aumento dos níveis de atendimento e a redução de custos de cadeia de suprimentos. Atrasos na entrega de suprimentos como produtos químicos e tubos podem resultar em tempo de parada de sondas, cujas taxas diárias de afretamento representam o maior custo na perfuração e na completação de um poço. Para tratar o problema foi formulado um modelo de otimização estocástica linear com variáveis positivas reais e inteiras. Dada a dificuldade de se resolver modelos de otimização com incerteza, vários métodos de resolução (discretização de cenários, aproximação por média amostral, aproximação por *latin hypercube sampling* e redução de cenários por *backward induction*) foram usados. Os resultados mostram as diferenças entre cada um dos métodos de resolução e os custos elevados de se usar modelos determinísticos que usam a média como parâmetro, ou seja, a inclusão de incerteza nos modelos é essencial para redução de custos e melhoria de eficiência.

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

STOCHASTIC PROGRAMMING OF DRILLING RIGS' SUPPLIES

Bruno Ferreira Vieira

March/2014

Advisor: Virgílio José Martins Ferreira Filho

Department: Production Engineering

The goal of this work is to use techniques of stochastic programming to reduce logistic costs regarding supplies to offshore drilling rigs. Since there is an increasing number of wells that need to be drilled for PETROBRAS' oil production to reach its expected growth over the next ten years, it is fundamental to increase service levels and to reduce supply-chain offshore costs. Delays in deliveries of supplies such as chemicals and pipes may result in the interruption of the activities of a drilling rig, whose daily rates represent the highest cost in the drilling and completion of a well. To deal with this problem, it was formulated a stochastic linear optimization model with mixed-integer decision variables. Due to the difficulty in solving models with uncertainty, several resolution methods (scenario discretization, sample average approximation, approximation by latin hypercube sampling and scenario reduction by backward induction) so that the optimal solution be found. The results show the differences between the resolution methods and the high costs of using deterministic models that use the mean as a parameter, to wit, including uncertainty is essential for reducing costs and improving efficiency levels.

SUMÁRIO

I – INTRODUÇÃO	1
II – METODOLOGIA E LITERATURA	4
II.1 – Breve Histórico da Programação Estocástica	4
II.2 – Modelo de Dois Estágios.....	5
II.3 – Modelo Multiestágios.....	6
II.4 – Modelos com Restrições de Probabilidade.....	8
II.5 – Modelos com Medidas de Risco.....	9
II.6 – Valor da Informação Perfeita (EVPI) e Valor da Solução Estocástica (VSS).....	12
II.7 – Técnicas de Abordagem de Modelos Estocásticos.....	13
II.8 – Modelos Estocásticos em Cadeia de Suprimentos.....	16
II.9 – Síntese.....	19
III – O PROBLEMA DE SUPRIMENTO DE SONDAS <i>OFFSHORE</i>	20
III.1 – Aspectos Relevantes na Perfuração Offshore	20
III.1.1. – Etapas de Perfuração.....	22
III.1.2. – Produtos Químicos.....	23
III.2 – Logística na Exploração e Produção Offshore.....	24
III.2.1 – Dimensionamento de Sondas	24
III.2.2 – Sequenciamento de Projetos de Exploração com Restrição de Sondas	24
III.2.3 – Dimensionamento de Equipamentos Críticos para Atividades de Poço	25
III.2.4 –Planejamento e <i>Scheduling</i> de Frota <i>Offshore</i> e de Instalações Submarinas	26
III.3 – Descrição do Problema	27
III.3.1 – Modelo Conceitual	28
III.3.2 – Hipóteses adotadas	32
III.3.3 – Síntese	36
IV – MODELO MATEMÁTICO	37
IV.1. – Formulação Matemática.....	37
IV.2. – Modelo sem Roteamento	41
IV.2.1 – Função Objetivo.....	41
IV.2.2 – Balanço de Massa	45
IV.2.3 – Limitações de Peso	47
IV.2.4 – Restrições de Não-Antecipatividade.....	47
IV.3 – Modelo com Roteamento	48
V – MÉTODOS DE RESOLUÇÃO: ABORDAGENS ESTOCÁSTICAS E ROTEIRIZAÇÃO	52
V.1 – Abordagens Estocásticas.....	52
V.1.1 – Modelo Discretizado	52
V.1.2 – Modelo com Sample Approximation Average (SAA)	57
V.1.3. – Modelo com <i>Latin Hypercube Sampling</i> (LHS)	58
V.1.4. – Modelo para obtenção de limites superiores.....	59
V.1.5. – Modelo com resolução por redução de cenários	59
V.2 – Algoritmo usado para roteamento	62
VI – CASO DE APLICAÇÃO	64
VI.1 – Dados	64
VI.1.1 – Distância	64
VI.1.2 – Parâmetros de Peso	65
VI.1.3 – Parâmetros de Estoque	65
VI.1.4 – Parâmetros de Custo.....	66
VI.2 – Análise das Variáveis Estocásticas	68
VI.2.1 – Distribuição de Probabilidade da Demanda de Produtos Químicos	68
VI.2.2 – Distribuição de Probabilidade de Demanda de Tubos	71
VI.3 – Resultados dos Métodos de Resolução sem Roteamento.....	72
VI.3.1 – Resultados do Modelo sem Roteamento Discretizado	72
VI.3.2 – Resultados do Modelo sem Roteamento com <i>Sample Approximation Average</i> (SAA).73	

VI.3.3 – Resultados do Modelo sem Roteamento com <i>Latin Hypercube Sampling</i> (LHS)	76
VI.3.4 – Resultados do Modelo sem Roteamento para Obtenção de Limites Superiores	77
VI.3.5 – Resultados do Modelo sem Roteamento com Redução de Cenários	78
VI.4. – Resultados dos Métodos de Resolução com Roteamento	79
VI.4.1 – Resultados dos Métodos de Resolução com Roteamento Discretizados	80
VI.4.2 – Resultados dos Métodos de Resolução com Roteamento e com SAA	81
VI.4.3 – Resultados dos Métodos de Resolução com Roteamento e com LHS	84
VI.4.4 – Resultados do Modelo com Roteamento para Obtenção de Limites Superiores	85
VI.4.5 – Resultados do Modelo com Roteamento e com Redução de Cenários	87
VI.5 – Síntese dos Principais Resultados	87
VII – CONCLUSÕES	89
REFERÊNCIAS BIBLIOGRÁFICAS	92
ANEXO I	98
ANEXO II	105

Lista de Figuras

Figura I.1 – Curva de produção projetada (fonte Petrobras).....	1
Figura III.1 – Imagem de navio sonda.....	21
Figura III.2 – Imagem de sonda semi-submersível	22
Figura III.3 Modelo sem roteamento	28
Figura III.4 Modelo com roteamento	29
Figure III.5 Navio de suprimento em atividade.....	30
Figura III.6 Navio de suprimento ocioso (fundeadado)	30
Figure III.7 Restrições de não-antecipatividade	32
Figura III.8 Tubos	34
Figura III.9 Produtos químicos	34
Figura III.10 Porto de Macaé	35
Figura V.1 – Árvore de decisão para produtos químicos	54
Figura V.2 – Árvore de decisão para tubos	54
Figura V.3 – Árvore de decisão para os tubos no método de redução de cenários	60

Lista de Tabelas

Tabela VI.1 – Testes de aderência das demandas de produtos químicos.....	70
Tabela VI.2 – Resultados do modelo sem roteamento discretizado	73
Tabela VI.3 – EVPI e VSS para o modelo sem roteamento discretizado	73
Tabela VI.4 – Resultados do modelo SAA sem roteamento com 1 amostra.....	74
Tabela VI.5 – Tamanho do modelo SAA sem roteamento.....	75
Tabela VI.6 – Resultados dos limites inferiores do modelo SAA sem roteamento	75
Tabela VI.7 – Resultados dos limites superiores do modelo SAA sem roteamento.....	76
Tabela VI.8 – Resultados do modelo LHS sem roteamento (dividido em 5 espaços equiprováveis)77	
Tabela VI.9 – Resultados para obtenção de limites superiores para modelo sem roteamento	78
Tabela VI.10 – Modelo sem roteamento e sem redução de cenários e com redução de cenários ..	79
Tabela VI.11 – Resultados do modelo discretizado com roteamento em ordem crescente	80
Tabela VI.12 – EVPI e VSS para o modelo discretizado com roteamento em ordem crescente.....	81
Tabela VI.13 – Resultados do modelo SAA com roteamento em ordem crescente com 1 amostra.81	
Tabela VI.14 – Tamanho do modelo SAA com roteamento.....	82
Tabela VI.15 – Resultados dos limites inferiores do modelo SAA com roteamento em ordem crescente	83
Tabela VI.16 – Resultados dos limites superiores do modelo SAA com roteamento em ordem crescente	83
Tabela VI.17 – Resultados do modelo LHS com roteamento em ordem crescente.....	85
Tabela VI.18 – Resultados para obtenção de limites superiores para modelo com roteamento em ordem crescente	86
Tabela VI.19 – Modelo com roteamento em ordem crescente sem redução de cenários e com redução de cenários	87

Lista de Abreviaturas

Abreviatura	Significado
CVar	<i>Conditional Value-at-risk</i>
EEV	<i>Expected Result of the Expected Value</i>
EV	<i>Expected Value</i>
EVPI	<i>Expected Value of Perfect Information</i>
LHS	<i>Latin Hypercube Sampling</i>
MIP	<i>Mixed Integer Programming</i>
PSV	<i>Platform Supply Vessel</i>
RP	<i>Recourse Problem</i>
SAA	<i>Sample Average Approximation</i>
Var	<i>Value-at-risk</i>
VSS	<i>Value of the Stochastic Solution</i>
WS	<i>Wait and See</i>

I – INTRODUÇÃO

Dados os planos arrojados para aumento da produção nacional nos próximos anos (a Petrobras planeja dobrar a produção em poucos anos com a entrada em operação das plataformas no pré-sal da bacia de Santos) e o aquecimento do mercado da indústria do petróleo, é preciso maximizar o uso de recursos críticos como sondas e suprimentos de sondas. Principalmente ao se levar em consideração os altos custos das sondas para águas ultra-profundas (cerca de US\$500.000 por dia), ou seja, uma sonda parada por falta de suprimentos causa grande prejuízo diário além de atrasar o cronograma de perfuração e completação de poços, que por consequência pode acarretar em adiamentos de produção de óleo, podendo inclusive afetar os planos de investimento de médio e de longo prazos.

Em resumo, falhas na programação da cadeia de suprimentos de uma empresa de petróleo na área de exploração e produção precisam ser minimizadas.

Seguem os planos de curva de produção para os próximos anos:




Figura I.1 – Curva de produção projetada (fonte Petrobras)

Nesse contexto, indústrias de grande escala, como a do petróleo, a de processos e a de produtos farmacêuticos têm investido mais na redução de custos de

estoque e de distribuição. Nesses ramos, a complexidade é enorme, dados o grande número de produtos e de centros de distribuição intermediárias.

Nos últimos anos com o aumento da velocidade de processamento dos computadores, tem ocorrido maior uso tanto na literatura acadêmica quanto nas empresas comerciais de softwares que permitam a inserção de modelos de programação estocástica, que consideram a incerteza inerente a modelos de maximização intertemporais. A eliminação dos piores cenários por meio de restrições probabilísticas também tem sido bastante usada quando se importa não só com o valor esperado mas também com a diminuição de riscos.

Nesse contexto a formulação de modelos logísticos estocásticos para redução de custos e riscos assume grande relevância para grandes empresas do ramo de petróleo, em particular para a Petrobras. O objetivo desse trabalho é propor um modelo para suprimento de sondas que incorpore incertezas nos modelos de logística *offshore* levando ainda em consideração as particularidades presentes nas operações das mesmas. Ao contrário de outros modelos de cadeia de suprimentos nos quais a demanda não-atendida de um produto resulta apenas na perda de um lucro por unidade de produto, no caso das sondas a falta de qualquer unidade de certos produtos pode levar a prejuízos enormes. Além disso, existe grande incerteza associada à demanda dos produtos pelas sondas. Ao considerar esses fatores relacionados às particularidades das atividades das sondas residem as contribuições dessa tese, já que esse ainda é um tema pouco abordado que apresenta grande potencial de ganhos na literatura de logística *offshore*.

O presente trabalho está organizado da seguinte forma. No capítulo II, são descritos as principais técnicas de programação estocástica e os papers mais relevantes encontrados na literatura acadêmica para o tratamento da programação estocástica de suprimentos de sondas. No capítulo III, serão feitas uma introdução aos principais aspectos de perfuração e de logística de poços *offshore*, uma descrição

completa do problema e serão enumeradas as premissas usadas para resolução. No capítulo IV, serão descritos os modelos e os métodos de solução usados. No capítulo V, serão descritos os dados utilizados e os critérios usados na determinação dos parâmetros e das funções de distribuição de probabilidade. No capítulo VI, serão analisados os resultados obtidos. Por fim, no capítulo VII, serão avaliados os resultados dessa tese de doutorado e os possíveis trabalhos posteriores.

II – METODOLOGIA E LITERATURA

A programação estocástica é uma estrutura para a modelagem de problemas que envolvem incerteza ao contrário dos problemas de otimização determinística que são formulados com a premissa de que os parâmetros são conhecidos (Sahinidis (2004)). Claramente essa premissa é bastante forte, em problemas reais dificilmente é verdadeira.

Destacando a importância de se medir as incertezas Birge e Louveaux (2012) afirmaram que “... de acordo com um ditado francês “Gérer, c’est prévoir”, que pode ser traduzido como “(A arte de) gerenciar está em prever.”” No presente, a probabilidade e a estatística nos ensinaram há muito tempo que o futuro não poder ser previsto perfeitamente mas deve ser tratado como aleatório ou incerto. O objetivo da programação estocástica está precisamente em achar uma decisão ótima em problemas com incerteza.

Além disso, como cita Grossmann (2012), a otimização de problemas de larga escala, entre os quais estão os de otimização com incerteza, busca soluções para problemas desafiadores que são difíceis de serem resolvidos por abordagens monolíticas, de modo que boas técnicas de modelagem e habilidade na formulação de algoritmos desempenham papéis fundamentais.

Nas seções seguintes serão feitos um breve histórico da programação estocástica e uma descrição de alguns dos principais modelos usados e papers pesquisados mais similares ao projeto em questão de programação estocástica de suprimentos de sondas.

II.1 – Breve Histórico da Programação Estocástica

A programação estocástica foi criada em meados do século XX e foi uma consequência dos avanços em programação linear e não-linear. Muitos anos passaram, entretanto, até que modelos eficientes de programação estocástica fossem formulados e analisados. Para uma revisão sobre modelos de otimização ver Biegler e Grossmann (2004) e para uma introdução sobre programação estocástica ver Birge e Louveaux (2012).

Atualmente, existe na teoria de programação estocástica uma grande variedade de modelos. Alguns dos principais são:

- modelos de dois estágios;
- modelos multiestágios;
- modelos com restrição de probabilidade;
- modelos com medidas de risco.

II.2 – Modelo de Dois Estágios

O modelo estocástico linear de dois estágios clássico foi formulado originalmente por Dantzig (1955) e Beale (1955). É um modelo básico de programação estocástica sendo que vários modelos mais complexos, como o multiestágios, derivam de alterações nas restrições ou na função objetivo do modelo de dois estágios.

O modelo é definido pelas seguintes equações¹:

$$\min z = c^T x + E_{\xi}[\min_{q(\omega)} y(\omega)] \quad (2.1)$$

$$s.t. Ax = b \quad (2.2)$$

$$T(\omega)x + Wy(\omega) = h(\omega) \quad (2.3)$$

$$x \geq 0, y(\omega) \geq 0 \quad (2.4)$$

¹ Os modelos apresentados nas próximas subseções II.2, II.3 e II.4 seguem a nomenclatura de Birge e Louveaux (2012).

As variáveis de decisão do primeiro estágio, que constituem as decisões tomadas com incerteza, são representadas por um vetor x ($n_1 \times 1$). Relativas também ao primeiro período são também o vetor c ($n_1 \times 1$ que muitas vezes é um vetor de custos), o vetor b ($m_1 \times 1$ em geral representa os recursos disponíveis) e a matriz A ($n_1 \times m_1$).

As variáveis de decisão do segundo estágio, que constituem as decisões tomadas após a resolução da incerteza, são representadas por um vetor y ($n_2 \times 1$). No segundo estágio, há a realização de um vetor de eventos aleatórios $\omega \in \Omega$, após a sua realização tornam-se conhecidos $q(\omega)$ (em geral o vetor de custos $n_2 \times 1$ da variável de decisão de segundo estágio na função objetivo), o vetor $h(\omega)$ (um vetor de recursos $m_2 \times 1$ das variáveis de decisão), e $T(\omega)$ (uma matriz $m_2 \times n_1$).

Ressalte-se que um único evento aleatório ω define todo o vetor de eventos estocásticos $\xi^T = (q(\omega)^T, h(\omega)^T, T_1(\omega)^T, \dots, T_{m_2}(\omega)^T)$, ou seja, o vetor pode ter até $n_1 + m_2 + (m_2 \times n_1)$ elementos.

A dificuldade computacional na resolução de problemas estocásticos de dois períodos reside na parte estocástica do modelo, que o torna muito mais complexo que o modelo determinístico.

II.3 – Modelo Multiestágios

O modelo multiestágios é uma generalização do modelo de dois estágios, no qual o número de períodos é aumentado.

Na vida real, a maior parte das decisões é intertemporal, ou seja, há vários períodos no qual são tomadas decisões com incerteza em cada período, aumentando a cada período o conjunto de dados disponíveis para o tomador de decisões.

Há vários modelos na literatura. Nesse trabalho, será usada a formulação proposta por Birge e Louveaux (2012), com número finito de períodos H e com uma matriz de recursos determinística W :

$$\min z = c_1 x_1 + E_{\xi_2}[\min c_2(\omega)x_2 + \dots + E_{\xi_H} \min c_H(\omega)x_H] \quad (2.5)$$

$$s.t. W_1 x_1 = h_1 \quad (2.6)$$

$$\begin{aligned} T_1(\omega)x_1 + W_2 x_2(\omega_2) &= h_2(\omega) \\ \dots & \\ \cdot & \end{aligned} \quad (2.7)$$

$$\begin{aligned} T_{H-1}(\omega)x_{H-1} + W_H x_H(\omega_H) &= h_H(\omega) \\ x_1 \geq 0; x_2 \geq 0, \dots, x_H \geq 0; t &= 2, \dots, H \end{aligned} \quad (2.8)$$

As variáveis de decisão x_i dependem do histórico até i , o que é visualizado no modelo pela expressão ω_i .

Na maioria dos modelos, supõe-se independência entre os resultados da variável aleatória nos diversos períodos. Além disso, supõe-se que a variável aleatória é exógena.

Nos últimos anos, os modelos multiestágios de programação estocástica têm sido usados com mais frequência (Grossman (2005)), em especial em modelos de otimização intertemporal de cadeias de suprimentos. Em geral, classificam-se as decisões em três níveis: o nível operacional (curto prazo), nível tático (médio prazo) e nível estratégico (longo prazo). Os modelos de programação estocástica multiestágios podem ser usados em todos esses níveis, visto que a premissa básica desses

modelos (a tomada de decisões com variáveis com incerteza) pode ocorrer em todos os níveis.

Conforme citam Gupta e Grossmann (2011) as restrições de não-antecipatividade, que desempenham a função de garantir a existência de incerteza, representam tipicamente 80% das restrições em problemas estocásticos multiestágios e são proporcionais ao quadrado do número de cenários, ou seja, dificulta-se muito o tratamento computacional de problemas do mundo real.

Inclusive grandes empresas como Petrobras, ver por exemplo Moraes (2013) e, Perdigão (vide <http://www.unisoma.com.br/br/casos-agroindustrias-4.php>) já tem usado modelos intertemporais com incerteza a fim de obterem melhores resultados.

II.4 – Modelos com Restrições de Probabilidade

A necessidade de garantia de altos níveis de qualidade de serviços para muitos empreendimentos ou o alto custo de falta de certos produtos é o que enseja o uso de modelos com restrições de probabilidade. No caso desse trabalho, os custo da não-entrega de suprimentos em sondas pode ser muito alto se levar à parada da sonda.

Mantendo o paralelismo com as seções anteriores, referente à nomenclatura das variáveis e parâmetros, segue a forma básica das restrições de probabilidade:

$$P\{A_i(\omega)x \geq h_i(\omega)\} \geq \alpha_i(\omega) \quad (2.9)$$

O parâmetro α é um percentual ($0 < \alpha < 1$) que representa o nível de serviço que será prestado. Valores típicos empregados em problemas do gênero estão na faixa dos 80% a 95% (Kall e Wallace (1994)). Obviamente quando o valor é um ou zero, deixa de existir uma restrição de probabilidade. Saliente-se que quanto maior o

valor de α , maior tende a se tornar o valor ótimo da função objetivo, ou seja, há uma punição em se tentar reduzir o risco. O índice i ($1 \leq i \leq I$, sendo I o número de restrições de probabilidade) numera as restrições que devem ser satisfeitas conjuntamente.

II.5 – Modelos com Medidas de Risco

Além dos modelos com restrições de probabilidade, que impedem a ocorrência dos piores cenários, outra forma de lidar com o risco é a de inserir custos ao risco na função objetivo. Esse último tipo de abordagem é vantajosa quando a obtenção de altos níveis de serviço tem um custo elevado ou é inviável economicamente (You e Grossmann (2009)).

Os modelos que maximizam valor esperado como os de dois estágios e o de multiestágios partem da premissa bastante forte de que o tomador de decisão é indiferente ao risco, o que não ocorre na maioria dos casos. A tendência é a aversão ao risco, ou seja, o consumidor ou o tomador de decisão (representando as empresas) preferem receber um montante fixo igual ao valor esperado da função objetivo a receber um montante incerto mas de mesmo valor esperado (Mas-Collel et al. (1995)).

Uma das formas mais comuns de inclusão de risco é a inclusão de um termo relativo à variância na função objetivo. Uma típica função objetivo desse tipo é:

$$\min z = c^T x + E_{\xi}[\min q(\omega)^T u(\omega)] + \rho \text{Var}_{\xi}[\min q(\omega)^T u(\omega)] \quad (2.10)$$

Com a inserção desse novo termo, tende-se a obter uma menor variabilidade em troca de um maior custo esperado. O termo ρ representa o custo por unidade de variância (quanto maior, mais avesso ao risco é o tomador de decisão).

Uma das críticas a esse tipo de modelo é a inclusão de termos quadráticos na função objetivo, o que torna mais complexa a resolução do problema, ainda mais em modelos de larga escala. Além disso, os cenários muito bons, que também contribuem para o aumento da variância, causam custo maior na função objetivo. Uma forma de evitar essas dificuldades consiste em inserir na função objetivo apenas os módulos dos conjuntos de probabilidades que apresentem custo maior que o custo esperado. Para casos discretos ou que sejam discretizados Ahmed e Sahinidis (1998), propuseram o seguinte índice de variabilidade:

$$\Delta_s \geq z_s - \sum_s p_s z_s, \Delta_s > 0, s \in S \quad (2.11)$$

Sendo que z_s representa o custo total em cada cenário e p_s representa a probabilidade de que cada cenário ocorra.

A função objetivo ganha então a seguinte forma:

$$\min E_z(z) + \rho \sum_{s \in S} p_s \Delta_s \quad (2.12)$$

Mais uma vez ρ constitui o parâmetro com o peso relativo a cenários ruins na função objetivo e pode variar bastante de acordo com as necessidades de cada tomador de decisão.

Ressalte-se que esses modelos de programação estocástica têm sido também usados em finanças (Barbaro e Bagajewicz (2004)).

Grossmann (2012) afirma que a vantagem da otimização robusta é que os métodos são mais tratáveis que os de programação estocástica (Li et al. (2011)).

Gebreslassie et al. (2012) usam um modelo com função multiobjetivo sendo que uma das funções objetivo é a tradicional minimização da função custo e a outra uma função de minimização do risco.

Para medir o risco Gebreslassie et. al. (2012) usam medidas de risco, a primeira é a de *downside risk* representada pelas equações abaixo:

$$\psi_s \geq \text{Custo}_s - \Omega, \quad \psi_s \geq 0, \quad s \in S \quad (2.13)$$

$$\min \text{Drisk}(x, \Omega) = \sum_{s \in S} p_s \cdot \psi_s(x, \Omega) \quad (2.14)$$

A equação 2.13 indica que quando o custo de um cenário for maior que o limite (Ω), então ψ (a variável de risco é maior que zero).

A equação 2.14 é a função objetivo.

A segunda medida de risco é a *CVaR* (Valor em Risco Condicional, do inglês *Conditional Value at Risk*) que é baseado nas seguintes equações (Gebreslassie et. al.(2012)):

$$\text{VaR} \geq 0 \quad (2.15)$$

$$\phi_s \geq \text{Custo}_s - \text{VaR}, \quad \phi_s \geq 0, \quad s \in S \quad (2.16)$$

$$\min \text{CVaR}(x, \alpha) = \frac{\sum p_s \cdot \phi_s}{1 - \alpha} + \text{VaR}, \quad \alpha \in (0,1) \quad (2.17)$$

O VaR (*value-at-risk*) é definido, a um dado intervalo de confiança, como o valor mínimo com probabilidade maior ou igual a α de o custo exceder ou igualar esse valor.

No modelo de Gebreslassie et. al. (2012), os autores concluem que a medida de risco $CVar$ é mais adequada que o *downside risk*, pois a probabilidade de ocorrência de cenários de baixo custo é maior que com o *downside risk*. Além disso, o modelo com *downside risk* depende muito da escolha de Ω .

II.6 – Valor da Informação Perfeita (EVPI) e Valor da Solução Estocástica (VSS)

O Valor da Informação Perfeita (EVPI em inglês) é uma das medidas mais comuns² para mensurar o valor da incerteza de um problema estocástico:

$$EVPI = RP - WS \quad (2.18)$$

Sendo que RP é o valor da solução do problema estocástico (RP - problema de recurso) e WS é o valor da solução se fosse pudesse possível esperar e ver (*wait and see*) o resultado, ou seja, se o problema não tivesse incerteza. O $EVPI$ é tradicionalmente definido como o valor que o planejador estaria disposto a pagar pela informação perfeita.

Já o valor da solução estocástica (VSS) representa o ganho do planejador ao levar em consideração a distribuição das funções de probabilidade das variáveis estocásticas e, não, apenas a média (EV) conforme é feito em um problema determinístico.

² A notação matemática dessa subseção se baseia em Birge e Loveaux (2012).

$$VSS = EEV - RP \quad (2.19)$$

EEV é o valor esperado da solução determinística que usa a média das variáveis estocásticas como parâmetro. É definido pela equação:

$$EEV = E_{\xi}(z(\bar{x}(\bar{\xi}), \bar{\xi})) \quad (2.20)$$

O EEV mede o quanto $\bar{x}(\bar{\xi})$ custa de modo que as decisões de segundo estágio são tomadas otimamente a partir das decisões de primeiro estágio.

II.7 – Técnicas de Abordagem de Modelos Estocásticos

Como o uso de distribuições contínuas pode gerar dificuldades computacionais, o uso de amostragem de Monte Carlo tem se tornado bastante popular, pois permite uma grande diminuição de tempo de processamento com pequena perda de precisão (Mak et al. (1999)).

O nível de acurácia por Monte Carlo pode ser escolhido pelo usuário como mostra Shapiro (2000) e Ruszczyński e Shapiro (2003), com a seguinte expressão que é válida independentemente da distribuição de probabilidade dos parâmetros incertos:

$$S(n) = \frac{\sqrt{\sum_{s=1}^n (E(z) - z_s)^2}}{\sqrt{(n-1)}} \quad (2.21)$$

Sendo $S(n)$ um estimador não-enviesado da variância de uma amostra de tamanho n , s é o índice dos cenários e z é variável de custo.

Conforme Shapiro e Homem-de-Mello (2001), o uso de amostragens de Monte Carlo pode ser usado para obter limites superiores e inferiores para o problema de otimização estocástica de dois estágios. O problema de dois estágios pode ser formulado da seguinte forma:

$$v^* = \min_{x \in X} \{f(x) = E_{\omega}[F(x, \omega)]\} = \int_{\Omega} G(x, \omega) g(x) dx \quad (2.22)$$

Isso fica claro ao se fazer as seguintes definições:

$$\begin{aligned} X &= \{x \mid Ax = b\} \\ f(x) &= c^T x + Q(x) \\ Q(x) &= E_{\omega}[Q(x, \omega)] \\ Q(x, \omega) &= \min_y \{q^T y \mid Wy = h(\omega) - Tx\} \end{aligned} \quad (2.23)$$

A principal dificuldade de resolução consiste no cálculo da integral. A abordagem por Monte Carlo ou *Sample Average Approximation*, visa a obter uma aproximação com N cenários por:

$$\hat{v}_N = \min_{x \in X} \left\{ \frac{1}{N} \sum_{n=1}^N F(x, \omega^n) \right\} \quad (2.24)$$

Como provam Shapiro e Homem-de-Mello (2001) esse é um estimador para o limite inferior para o problema, já que:

$$E_{\omega}(\hat{v}_N) \leq v^* \quad (2.25)$$

A dificuldade está em obter o valor da esperança que é aproximado pelo uso de A amostras independentes e identicamente distribuídas (i.i.d):

$$L_{N,A} = \frac{1}{A} \sum_{a=1}^A \hat{v}_{N,a} \quad (2.26)$$

Sendo $L_{N,A}$, o limite inferior com N cenários e A amostras.

Para se obter um estimador não-enviesado para a variância do limite inferior, pode-se usar:

$$s_L^2 = \frac{1}{A-1} \sum_{a=1}^A (\hat{v}_{N,a} - L_{N,A})^2 \quad (2.27)$$

Por fim, com uma tolerância α , pode-se definir um intervalo de confiança $((1-\alpha)$ ver Casella e Berger (2002)) para $L_{N,A}$:

$$\left[L_{N,A} - \frac{z_\alpha s_L}{\sqrt{A}}, L_{N,A} + \frac{z_\alpha s_L}{\sqrt{A}} \right] \quad (2.28)$$

Sendo z_α o valor do desvio de uma distribuição normal padrão tal que $P(z \leq z_\alpha) = 1-\alpha$.

Já para se obter um limite superior pode-se usar uma solução perto do ótimo, o mais usual é a solução de x (denotada por \hat{x}) com um conjunto de cenários por SAA. Em seguida são geradas A amostras com N cenários cada, sendo tanto as amostras quanto os cenários i.i.d. Assim, para cada amostra:

$$\hat{f}_N = \frac{1}{N} \sum_{n=1}^N F(\hat{x}, \omega^n) \quad (2.29)$$

O estimador do limite superior ($U_{N,A}$) será a média dos resultados das A amostras:

$$U_{N,A} = \frac{1}{A} \sum_{a=1}^A \hat{f}_{N,a} \quad (2.30)$$

Novamente, para se obter um estimador não-enviesado para a variância do limite inferior, pode-se usar:

$$s_U^2 = \frac{1}{A-1} \sum_{a=1}^A (\hat{f}_{N,a} - U_{N,A})^2 \quad (2.31)$$

Por fim, com uma tolerância α , pode-se definir um intervalo de confiança $(1 - \alpha)$ para $U_{N,A}$:

$$\left[U_{N,A} - \frac{z_{\alpha} S_U}{\sqrt{A}}, U_{N,A} + \frac{z_{\alpha} S_U}{\sqrt{A}} \right] \quad (2.32)$$

Hollmann (2011) propôs uma heurística chamada *Adaptive Scenario Refinement* (ASR) para a geração de cenários para a resolução de problemas estocásticos inteiros.

Para o caso de modelos estocásticos multicenários com grande número de cenários, Karupiah et al. (2010) propõem uma heurística para redução do número de cenários.

Conforme sugerem Homem-de-Mello e Bayraksan (2013) e Linderoth et al. (2006), para redução da variância amostral têm sido usados outros métodos além de Monte Carlo. O *Latin Hypercube Sampling* (LHS) é um desses métodos, introduzido por McKay et al. (1979), e se baseia na decomposição do espaço amostral em N partições equiprováveis para em seguida gerar amostras aleatórias em cada um desses N espaços. Por fim, são feitas permutações aleatórias entre os N subespaços. Em geral, geram-se valores aleatórios de distribuições uniformes $(0;1)$ e depois usa-se uma função inversa cumulativa da distribuição de probabilidade. Um problema do LHS é que as amostras não são independentes, ou seja, os resultados clássicos do teorema do limite central não se aplicam, e os intervalos de confiança não podem ser construídos de forma convencional. Para contornar esse problema, têm sido geradas várias replicações de tamanho N e usa-se a média de cada replicação como estimador.

II.8 – Modelos Estocásticos em Cadeia de Suprimentos

Na literatura, os modelos mais similares aos de logística de suprimentos de sondas que incluem incerteza foram os encontrados em modelos de cadeia de suprimentos da indústria de processos que assim como a indústria do petróleo também representam sistemas de larga escala que envolvem valores monetários muito altos.

Dada a crescente competição na área de cadeia de suprimentos e o desenvolvimento de ferramentas matemáticas para otimização em larga escala, modelos de otimização inclusive com grande número variáveis e restrições têm sido usados com sucesso para reduzir custos e riscos.

Conforme afirmou Grossmann (2005), há grande interesse entre uma variedade de indústrias como a do petróleo em atingir o objetivo de otimizar toda a cadeia produtiva.

Vários artigos têm sido escritos para tratar as incertezas envolvidas em modelos de cadeia de suprimentos. Subrahmanyam et al. (1994) constitui um exemplo de busca de valores de variáveis que apresentassem resultados ao menos medianos em todos os cenários. A dificuldade de modelos baseados em cenários é o crescimento exponencial do tamanho do problema quando o número de cenários aumenta.

O artigo de You et al. (2009), no qual é usado um modelo estocástico para lidar com as incertezas e para redução do custo esperado, é um bom exemplo de modelo que pode ser adaptado de artigos de otimização em cadeia de suprimentos para a indústria do petróleo. Como escreveu Grossman (2005), a área de otimização ao longo da cadeia de suprimentos usa bastante o conhecimento da área de pesquisa operacional. O modelo de You et al. (2009) visa a reduzir os custos esperados totais de uma cadeia de indústria de produtos químicos com fábricas, centros de distribuição e consumidores espalhados no mundo. Com abordagem similar também foi o artigo de Poojari et al. (2008).

A premissa de You et al. é de que a demanda e as taxas de frete são variáveis estocásticas, as outras variáveis tais como tempo de transporte e custo de falta do produto são determinísticas. A variável de decisão é a quantidade a ser transportada em cada cenário e em cada período.

Outro aspecto nesse modelo é o aumento da incerteza quando se aumenta o número de períodos para o qual a previsão é feita. Em outras palavras, a margem de erro é menor para períodos mais próximos do atual.

Apesar de modelos determinísticos fornecerem resultados de implementação mais fácil, apresentam em geral resultados finais piores, pois são consideradas apenas os valores médios das variáveis.

De modo a tentar corroborar as vantagens do uso de modelos estocásticos em relação aos determinísticos, You et al. (2009) comparou os resultados obtidos de modelos determinísticos nos quais eram usados simplesmente os valores médios da demanda e da taxa de frete com os de modelos estocásticos e verificou que os custos esperados eram cerca de 5% menores nos modelos estocásticos.

Oliveira (2012) usa modelos de programação estocástica para otimização com incerteza na cadeia de suprimentos do setor de petróleo (*downstream_* na distribuição de produtos derivados do petróleo).

Schutz et al. (2009) propõe a resolução de um modelo de desenho de cadeia de suprimentos com incerteza usando aproximação por média amostral (SAA em inglês) e usam relaxação lagrangeana, como algoritmo de solução. Para o uso de SAA em modelos estocásticos multiestágios ver Shapiro (2005) e para descrição do algoritmo para SAA ver Kleywegt et al. (2001).

Papers recentes, como Hashem et al. (2012) incluem o uso de algoritmos genéticos para a resolução de um modelo multiobjetivo robusto de planejamento agregado de produção.

Khor (2012) propõe um algoritmo, que tem o objetivo de ter um menor custo computacional, similar ao de You et al. (2009) usando *CVaR* como medida de risco para solução de modelo estocástico de planejamento de refinaria.

Quando o número de cenários é muito grande de modo a impossibilitar o tratamento computacional do problema, seja por falta de memória ou por tempo excessivo na resolução do problema, técnicas de redução de cenários têm sido usadas a partir do *paper* de Heitsch e Romisch (2003).

II.9 – Síntese

Nessa seção foi feita uma breve apresentação sobre os principais modelos de programação estocástica e, dada a complexidade de resolução de modelos de otimização estocástica (muitas vezes a solução só poder ser obtida por métodos numéricos), foram apresentados os principais métodos de resolução usados na literatura, entre eles métodos de redução de cenários e métodos de aproximação por médias amostrais.

III – O PROBLEMA DE SUPRIMENTO DE SONDAS *OFFSHORE*

Neste capítulo é descrito o problema objeto deste trabalho. Inicialmente, são apresentados os aspectos relevantes na perfuração offshore que definem o contexto em que o problema se encontra. A seguir uma breve revisão bibliográfica mostra problemas correlatos existentes na literatura. Por fim o problema é descrito.

III.1 – Aspectos Relevantes na Perfuração Offshore

O objetivo na perfuração de um poço offshore de petróleo é que a perfuração seja feita o mais rapidamente possível satisfazendo todas as restrições de tecnologia, de qualidade e de segurança. Esses objetivos são muitas vezes conflitantes e sujeitos a incertezas significativas (Thomas (2004)). A construção de poços *offshore* depende de fatores que podem ser interdependentes e estocásticos:

- formação geológica (complexidade, tipo da formação). Em geral, os poços são classificados em: exploratórios nos quais não há reservas provadas de petróleo e de desenvolvimento que estão em campos com reservas provadas. Nos poços exploratórios, a incerteza é maior, ou seja, a perfuração é feita com mais cuidado pois o risco de *blowout* (fluxo descontrolado de líquidos e gases vindos da formação (paredes do poço)). Assim, o custo de poços exploratórios tende a ser maior que o custo de poços em desenvolvimento;
- características do local (profundidade, distância da costa, condições climáticas). Para modelos com inclusão das condições climáticas nas restrições, ver Shyoshu et al. (2010);
- fatores exógenos (gerenciamento de projeto, experiência dos operadores);
- condições de mercado (oferta e demanda de sondas).

Como mostra Westney (2001), o adequado gerenciamento de riscos de projetos *offshore* é essencial para aumentar as probabilidades de sucesso de um projeto, além de facilitar a redução de custos e diminuir a possibilidade de que más decisões sejam tomadas.

A construção de poços marítimos é composta de quatro fases: desenho e planejamento, que são geralmente iniciadas por geólogos e engenheiros de reservatório e depois encaminhadas aos engenheiros de perfuração, execução que costuma ser acompanhada com atenção já que os custos com perfuração representam em média de 40 a 60% dos custos de capital para desenvolvimento de um campo (Kaiser (2009)) e a análise na qual pode ser feita uma avaliação do projeto como um todo. Dados os altos custos e o uso de informações para poços na mesma área, são feitos registros meticulosos sobre a construção de cada poço.

Em geral, a estimativa de custos é feita por meio da decomposição de custos, em que o engenheiro de poço estima tempos e custos esperados.

Em águas com profundidade superior a 500m, onde está a maioria da produção brasileira só podem ser usadas navios-sondas ou sondas-semisubmersíveis, conforme ilustram as figuras III.1 e III.2:



Figura III.1 – Imagem de navio sonda



Figura III.2 – Imagem de sonda semi-submersível

“Ao longo das últimas décadas, vários métodos foram propostos para avaliar custos e complexidade de perfuração, mas devido ao grande número de fatores que causam impacto na avaliação de desempenho, é difícil construir modelos preditivos” (Kaiser (2007)). No Golfo do México, a avaliação da performance de perfuração tem alta visibilidade entre o comando das empresas. Ao longo dos anos uma variedade grande de modelos de custos foi desenvolvido mas essas técnicas são em geral confidenciais e os dados não estão disponíveis ao público (Ibid.).

III.1.1. – Etapas de Perfuração

Os poços são perfurados em estágios (Rocha e Azevedo (2009)):

1. Perfura-se até uma determinada profundidade;
2. Remove-se a broca e a coluna de perfuração;
3. São inseridos os revestimentos e feita a cimentação do revestimento às paredes do poço;
4. Volta-se à etapa 1 e perfura-se até outra profundidade.

A profundidade que será perfurada entre cada revestimento varia de acordo com as formações geológicas abaixo, sendo que a temperatura e a pressão tendem a ser maiores e a tornar mais lentas e complexas as atividades de perfuração.

III.1.2. – Produtos Químicos

Os produtos químicos desempenham importante função na perfuração. A lama de perfuração como é chamada tradicionalmente serve para:

- controlar as pressões da formação em diferentes profundidades;
- carregar o material que está sendo perfurado;
- lubrificar a broca;
- estabilizar as paredes da formação.

A lama de perfuração em geral consiste de quatro partes:

1. os fluidos de base que pode ser água, óleo, material sintético e caracterizam a base;
2. sólidos ativos que geram a viscosidade do sistema, em geral bentonita;
3. sólidos inertes que regulam a densidade do fluido;
4. outros aditivos que controlam propriedades químicas, físicas e biológicas da lama de perfuração.

Os produtos químicos são indispensáveis ao funcionamento da sonda e sua falta leva a tempo de sonda parada, ou seja, produz grandes prejuízos.

Para maiores detalhes sobre fluidos de perfuração ver Caenn e Chillingar (1996).

III.2 – Logística na Exploração e Produção *Offshore*

Na área da logística aplicada ao desenvolvimento de campos de petróleo, os principais problemas estudados na literatura (Mazzini et al. (2010)), todos abordados pela pesquisa operacional, são: dimensionamento de sondas, sequenciamento de projetos de exploração com restrição de sondas, dimensionamento de equipamentos críticos para atividades de poço e planejamento e *scheduling* de frota offshore e de instalações submarinas.

III.2.1 – Dimensionamento de Sondas

As sondas são recursos críticos nas operações de exploração e de desenvolvimento de campos, já que representam o item mais caro nas atividades de perfuração. É normal, portanto, a premissa de que o dimensionamento e a alocação de sondas devem ser feitas de forma independente de outros recursos. Em geral é tratado como um problema de simulação (Shyoshou et al. (2010)).

III.2.2 – Sequenciamento de Projetos de Exploração com Restrição de Sondas

Como afirma Tavares (2002), a pesquisa operacional tem dado construções científicas essenciais para o desenvolvimento da área de gerenciamento de projetos por meio do desenvolvimento de algoritmos que auxiliam no suporte às decisões gerenciais.

O objetivo é definir o ordenamento de um conjunto de tarefas que resulte no menor tempo possível de modo que sejam respeitadas as relações de precedência entre as tarefas e os limites de recursos a cada instante de tempo.

Esse tipo de problema é geralmente tratado na literatura como um problema de programação matemática (Blazewicz (1991)), por programação inteira. São problemas NP-árduo (Blazewicz et al. (1983)).

Como afirma Vasconcellos (2006), a definição de sequenciamento de projetos constitui um problema de otimização combinatória de difícil solução dada a não-convexidade do espaço de soluções. Por essa razão, são muito usados algoritmos não-exatos, heurísticas e meta-heurísticas. Vasconcellos (2006) usou algoritmos genéticos para a solução do problema, tendo como objetivo obter minimizar o tempo para a realização de todos os projetos (*makespan* mínimo).

Conforme Tavares (2002), projetos mais realistas adotam a hipótese de estocasticidade para representar a incerteza do projeto. As incertezas em geral se referem à duração e ao custo das operações para cada atividade. Para exemplos de modelos com correlação entre as variáveis de custo e de duração e com uso do valor presente líquido na função objetivo ver Tavares et al. (1998).

III.2.3 – Dimensionamento de Equipamentos Críticos para Atividades de Poço

Entre os principais problemas relacionados à logística de perfuração e desenvolvimento de campos de petróleo, esse é o de escopo mais similar ao que pretende se tratar nessa tese.

Considera-se geralmente que, após a definição do dimensionamento de sondas e o sequenciamento, deve-se selecionar o dimensionamento dos equipamentos críticos necessários em sondas de perfuração.

Mazzini et al. (2010) formularam um modelo para dimensionamento de recursos críticos necessários nas sondas para atividades de perfuração, completação e restauração de poços. Esses recursos críticos precisam ser contratados com antecedência em alguns casos de até um ano com o objetivo de atender as atividades do cronograma de sondas da companhia. Fazem parte dessa lista que tem aproximadamente 50 itens: motor de alto torque, chave hidráulica, unidade de perfilagem, coluna de assentamento e medidor de inclinação. Materiais de consumo não foram considerados no modelo pois são de fácil aquisição e não são objetos de contrato.

A ausência de um equipamento para a atividade prevista da sonda leva a custos de sonda parada além do atraso nos projetos da empresa com diminuição de valor presente líquido.

O foco do modelo de Mazzini et al. (2010) é econômico sendo que a sequencia de projetos do cronograma não é alterada, ou seja, não se altera o sequenciamento pré-definido em etapa anterior. Apenas é permitido o atraso de atividades para as quais haja indisponibilidade de equipamentos. A função objetivo é composta por duas parcelas: o custo de contratação de equipamentos e o custo de atraso das sondas.

O modelo com variáveis binárias e inteiras foi rodado usando como dados o cronograma de atividades de sondas da Petrobras para as regiões Sul e Sudeste no ano de 2011. O resultado mais significativo foi a não-otimalidade de um nível de serviço de 100%. Em outras palavras, se o custo de atraso de sondas for zero, aumenta-se muito o custo de contratação de equipamentos de modo que há gastos adicionais de cerca de U\$40 milhões em relação à solução ótima com nível de serviço de 95,4%.

III.2.4 –Planejamento e *Scheduling* de Frota *Offshore* e de Instalações Submarinas

Trabalhos recentes nessa área incluem o de Leite (2012), no qual são descritas as operações de logística *offshore* da Petrobras na Bacia de Campos. Dados os problemas existentes na programação de *PSVs* (*Platform Supply Vessels*), Leite propõe uma nova estratégia que visa a diminuir o número de viagens de *PSVs* sem diminuir o nível de serviços. De acordo com as simulações feitas com base em dados históricos, pode-se diminuir substancialmente os custos logísticos.

Já Uglane e Friedberg (2012) implementaram um modelo determinístico de otimização para geração de rotas e *scheduling* de *PSVs* na Bacia de Campos.

Cruz (2013) implementou um modelo com incerteza para *scheduling* de arranjos submarinos para produção *offshore*, usando diversas metodologias para sua resolução.

III.3 – Descrição do Problema

O problema tratado é abordado por programação estocástica e será resolvido por diversos métodos que serão descritos no capítulo V.

Na seção III.3.1 será explicado o modelo conceitual que inclui:

- modelo sem roteamento e com roteamento;
- dados de entrada;
- variáveis de decisão
- restrições.

Além disso, serão descritas as hipóteses usadas no modelo de programação estocástica de cadeia de suprimentos na seção III.3.2 e será feita uma síntese na seção III.3.3.

III.3.1 – Modelo Conceitual

Na primeira formulação será usado um modelo mais simples sem roteamento no qual se supõe que cada barco de suprimento carrega no porto, descarrega em uma única plataforma e depois retorna ao porto, conforme ilustrado pela figura III.3:

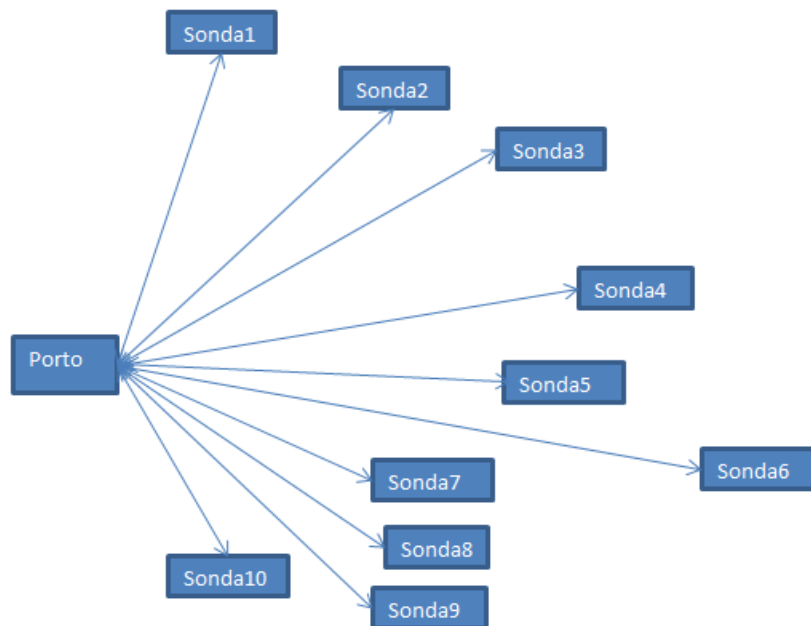


Figura III.3 Modelo sem roteamento

Na segunda formulação, o roteamento é incluído conforme ilustrado na figura III.4:

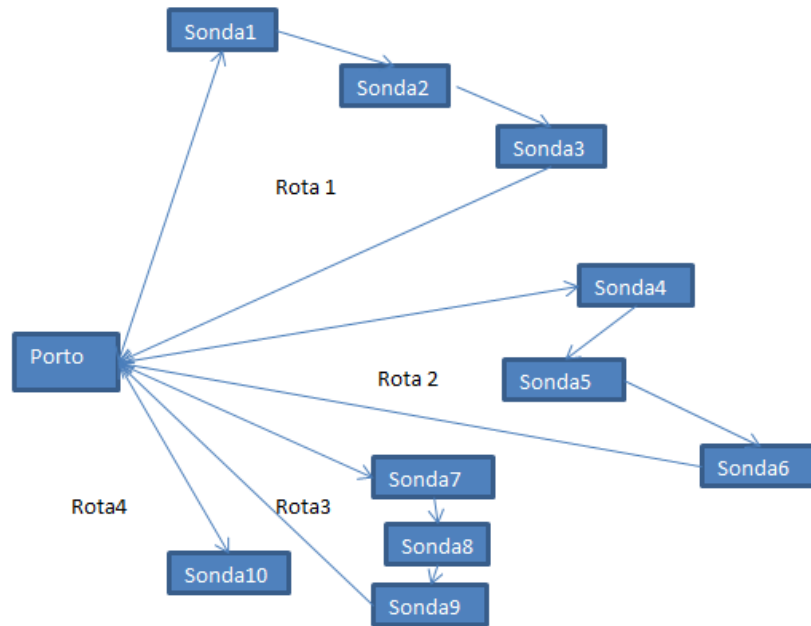


Figura III.4 Modelo com roteamento

Assim, na formulação com roteamento (mais próxima da realidade), a distância total a ser percorrida será bem menor, sendo, porém, necessário definir a rota a ser usada pelos barcos supridores.

Dados:

- localização geográfica do porto (no caso, Macaé) onde os barcos supridores carregam produtos a serem transportados para as sondas;
- conjunto de 10 sondas que realizaram atividades na Bacia de Campos entre 2010 e 2011 com suas respectivas: localizações geográficas, taxas diárias de aluguel e capacidades máximas de carga;
- a função de distribuição de probabilidade das demandas de cada um dos produtos (produtos químicos e tubos) de cada uma das sondas;
- conjunto de barcos de suprimento com suas respectivas: capacidades de transporte (medida em metros quadrados de convés), custo diário de afretamento e custos por distância percorrida;

- parâmetros usados para determinação dos custos (descritos no capítulo VI) e na determinação das condições do período inicial, principalmente o estoque inicial.

Variáveis de decisão:

- definição das rotas a serem percorridas por cada barco supridor (no problema com roteamento);
- definição se o barco de suprimento está em atividade ou ocioso também no modelo com roteamento (conforme figuras III.5 e III.6), o que dependerá do número total de barcos de suprimento e da realização das demandas;



Figure III.5 Navio de suprimento em atividade



Figura III.6 Navio de suprimento ocioso (fundeado)

- quantidades a serem transportadas por cada barco para cada plataforma em cada período;
- estoque de cada produto em cada plataforma e demanda não-atendida de cada produto em cada plataforma, esta variável de decisão pode ser calculada a partir da quantidade transportada. A demanda não-atendida seria como um estoque negativo, ou seja, a correlação entre estoque e demanda não-atendida é imediata.

O modelo tem o objetivo de minimizar o custo total esperado de cadeia de suprimento, que deve incluir:

- os custos de estoque, que levam em consideração o fato de ser custoso ter produtos que não estão sendo utilizados em cada sonda;
- os custos de falta de produtos que levam a tempo de sonda parada. A particularidade desse problema é que o custo de falta não é proporcional à demanda não-atendida. O custo de falta é o mesmo se faltar uma unidade de um produto ou se faltar 1.000 unidades de cada um dos produtos, já que a falta de qualquer unidade do produto leva à parada da sonda. O cômputo desse tipo de custo torna necessária a inclusão de variáveis binárias, o que aumenta a complexidade do problema;
- os custos de transporte dos barcos fornecedores, que será proporcional à distância percorrida no total e ao número de navios fornecedores ativos e ociosos;
- os custos de se estar abaixo do estoque de segurança, que representam uma forma de evitar falta de produtos;
- o custo de o barco de suprimento ter de retornar para fazer a entrega por falta de disponibilidade de área da sonda para receber o produto.

Na prática, esse problema ocorre com certa frequência e atrapalha bastante o cumprimento do planejamento.

Sujeito a restrições de:

- capacidade, já que tanto o barco supridor quanto às sondas têm uma capacidade máxima passível de transporte ou estoque respectivamente;
- restrições de rota, já que uma sonda pode ser atendida apenas por uma única rota;
- balanço de massa, que relaciona a quantidade transportada, demanda, estoque e demanda não-atendida nos diferentes períodos;
- restrições de não-antecipatividade, que fazem as decisões serem tomadas sob condições de incerteza que pode ser ilustrado pela figura III.7:

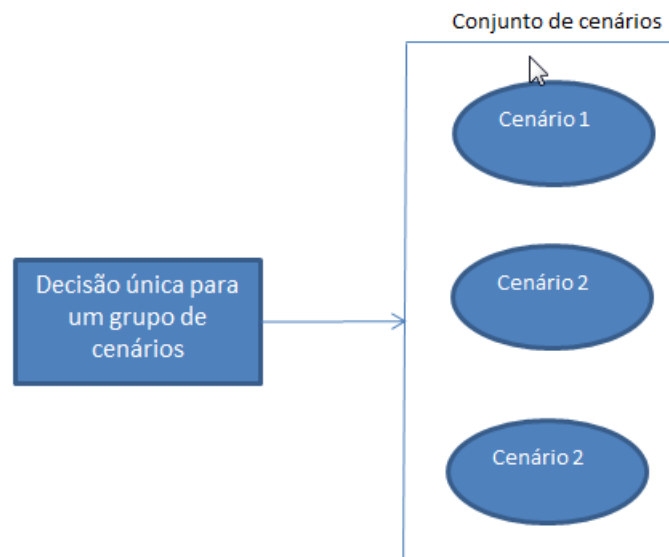


Figure III.7 Restrições de não-antecipatividade

III.3.2 – Hipóteses adotadas

Não foram consideradas no modelo variáveis como:

- clima que em condições adversas impede operações de navios supridores nas sondas;
- fatores não-observáveis, como gerenciamento de projeto, pois são de difícil mensuração;
- falhas mecânicas tanto nos barcos supridores quanto nas sondas.

É impossível identificar todas as características relevantes das atividades das sondas, é apenas possível estabelecer relações empíricas para medir o desempenho dessas operações (Kaiser e Pulsipher (2007)). Em suma, modelos feitos para retratar as operações de sondas necessariamente precisam de simplificações.

O modelo supõe um horizonte temporal de médio prazo (de 14 dias divididos em 2 períodos de 7 dias), ou seja, é feita uma entrega por semana. Esse número de períodos é menor que o normalmente utilizado (12 períodos ou 1 ano). A intenção dessa mudança é tornar o modelo mais adequado às demandas de produtos nas atividades desempenhadas pelas sondas, que precisam de entrega de suprimentos com uma frequência maior.

A atividade de uma sonda em um determinado poço pode também levar menos ou mais de um mês, dependendo da profundidade do poço, das características geológicas e das atividades realizadas.

Considerou-se que a programação das sondas já está definida, conforme usado em trabalhos como Mazzini et al. (2010), pois, como a definição do itinerário das sondas já é um problema bastante complexo, o mais usual é resolvê-lo separadamente.

Há incerteza sobre o tempo de cada operação (de perfuração ou completação da sonda) e com relação à demanda de cada sonda, por cada produto, em cada período.

Dadas as dificuldades computacionais de se lidar com muitas variáveis estocásticas, resolveu-se tratar apenas a demanda das sondas como variáveis incertas que foram separadas em dois produtos principais: tubos e produtos químicos cuja falta leva à parada da sonda.

Nos dois períodos é preciso decidir a quantidade a ser transportada antes da realização da demanda.



Figura III.8 Tubos



Figura III.9 Produtos químicos

Por meio de dados históricos relativos à Bacia de Campos, estimaram-se as distribuições apropriadas para simbolizar a função distribuição de probabilidade das demandas dos dois produtos (conforme será discutido no capítulo VI) por sonda, isto é, de vinte variáveis aleatórias.

Nesse trabalho, foi usada a hipótese de independência na demanda para esses dois produtos de sondas.

O modelo é composto por um porto (para o modelo foi considerado o porto de Macaé, que é um porto central para a Petrobras em todo o Sul-Sudeste) de onde são embarcadas todas as mercadorias que serão transportadas para as 10 sondas. Para simplificação, é suposto que não há problemas de estocagem, ou seja, os produtos estão sempre disponíveis no porto. Ressalte-se que essa premissa é realista, pois, de fato, as entregas para sondas na Bacia de Campos são feitas em condições normais por Macaé.



Figura III.10 Porto de Macaé

O *scheduling* dos barcos de suprimento nos piers do porto será considerado como dado.

Destaque-se que os modelos sem roteamento e com roteamento têm como premissa a homogeneidade da frota de rebocadores em relação aos principais aspectos:

- custo;
- velocidade;
- capacidade de armazenagem.

Ressalte-se a complexidade do modelo com roteamento que é composto por dois problemas bastante complexos:

- o problema de roteamento de veículos (no caso barcos supridores) que é NP-difícil;

- o problema de otimização sob incerteza para decidir as quantidades a serem transportadas de cada produto, para cada sonda, em cada período.

Como forma de tornar o problema tratável, foi criado um meta modelo com duas etapas:

1. uso de uma heurística para definição das rotas a serem percorridas por cada navio supridor (descrita no capítulo V);
2. modelo de programação estocástica cujos métodos de amostragem e resolução serão descritos no capítulo V, no qual se definem os estoques e as quantidades a serem transportadas.

III.3.3 – Síntese

Em suma, o objetivo do modelo é executar o planejamento, tendo como base um modelo de cadeia de suprimentos, para entrega de produtos (tubos e produtos químicos) com demanda altamente estocástica para suprimentos de sondas, levando em consideração as particularidades das operações *offshore*.

IV – MODELO MATEMÁTICO

O problema tratado é abordado por programação estocástica e será resolvido por diversos métodos, sendo que na primeira formulação será usado um modelo mais simples, sem roteamento, no qual se supõe que cada barco de suprimento carrega no porto, descarrega em uma única plataforma e depois retorna ao porto. Na segunda formulação, o roteamento é incluído.

IV.1. – Formulação Matemática

Sejam os seguintes conjuntos :

- Sondas, conjunto S;
- Produtos, conjunto P;
- Períodos, conjunto T;
- Cenários, conjunto C;
- Rotas, conjunto R de todas as rotas possíveis.

Índices:

- s é o índice de cada sonda (no caso, varia de 1 a 10);
- p é o índice de cada produto (no caso, pode ser 1 ou 2);
- t é o índice de cada período (no caso, poder 1 ou 2);
- c é o índice de cada cenário;
- r é o índice de cada rota;

- $C_{g,p}$ Grupo de cenários ligados ao produto p ;
- $C_{g,r}$ Grupo de cenários ligados à rota r .

Parâmetros³:

- a é o número de amostras, sendo que cada amostra têm n cenários;
- $CapPSV$ é a capacidade de armazenamento do PSV em metros quadrados descontada a folga do *backload* (descarga de produtos da sonda para o navio supridor);
- CF_s custo de falta por sonda, que implica custo de sonda parada;
- $Cl_{s,p}$ custo de estocagem por produto por sonda;
- $CoefSeg$ é um coeficiente de segurança usado para a obtenção do custo de transporte total esperado;
- CR custo de retorno do rebocador;
- $CReb$ é o valor da diária do rebocador;
- $CReb_r$ é o custo do rebocador ao percorrer a rota r ;
- $CRebOc$ é o custo do rebocador ocioso, ou seja, o custo do rebocador que não está sendo usado pois outros já atendem a demanda das sondas;
- $CS_{s,p}$ custo de se estar abaixo do estoque de segurança por sonda por produto;
- CT é um escalar que representa o custo de transporte por distancia por unidade de produto;
- $DE_{s,p,t,c}$ é a demanda por produto, por sonda, por período. É a variável estocástica do problema;

³ O cálculo dos parâmetros será detalhado no capítulo VI.

- $Dist_{s,t}$ é a distância da sonda s ao porto no período t . Esse parâmetro é usado no modelo sem roteamento;
- ε é uma constante estritamente maior que zero, foi usado o valor de 0,00001;
- $IO_{s,p}$ é o estoque inicial por produto, por sonda;
- $IS_{s,p}$ é o estoque de segurança por produto, por sonda;
- LL é uma constante que representa um limite mínimo para atendimento de restrições;
- M_p é o peso por unidade de produto;
- $Mmax_s$ é o peso máximo por sonda;
- n é o número de cenários;
- P_c é a probabilidade de ocorrência de cada cenário;
- $RebT$ é número total de rebocadores disponíveis. Pode ser tanto um parâmetro quanto uma variável de decisão. Para o planejamento de curto prazo é um parâmetro e em termos de médio prazo pode ser uma variável de decisão. Como o foco desse trabalho é o planejamento de curto prazo, esse termo será tratado como um parâmetro e será igual a 6;
- UL_1 é uma constante que representa um limite máximo de estoque por produto por sonda;
- UL_2 é uma constante que representa um valor elevado para que as restrições de capacidade de sondas sejam sempre satisfeitas;
- VM é a velocidade média do rebocador;

Variáveis de decisão:

- $tr_{s,p,t,c}$ é a quantidade de cada produto que deve ser transportada para cada sonda em cada período em cada cenário antes de conhecido o valor da demanda estocástica;
- $i_{s,p,t,c}$ é o estoque em cada sonda de cada produto em cada período e em cada cenário. Apenas no primeiro período, o estoque é dado;
- $dn_{s,p,t,c}$ é a demanda não-atendida em cada sonda de cada produto, em cada período e em cada cenário.
- $w_{s,p,t,c}$ é o valor que se está abaixo do estoque de segurança em cada sonda, de cada produto, em cada período e em cada cenário.
- $y_{1,s,t,c}$ é uma variável binária que indica quando houve demanda não-atendida estritamente positiva em uma sonda de qualquer um dos dois produtos em um período em um dado cenário. Se for igual a 1, há demanda não-atendida de pelo menos um dos produtos. Se for igual a 0, não houve demanda não-atendida de nenhum dos produtos;
- $y_{2,s,p,t,c}$ é uma variável binária que indica quando houve demanda não-atendida estritamente positiva em cada sonda de cada produto, em um período, em um cenário. Se for igual a 1, a demanda não-atendida é igual a zero. Se for igual a 0, a demanda não-atendida é maior que zero;
- $y_{3,s,t,c}$ é uma variável binária que indica quando há necessidade de retorno do rebocador pois a capacidade de carga da sonda em peso da sonda seria violada. Quando for 1, significa que o rebocador precisa retornar depois. Caso contrário, não;
- $y_{r,s,t}$ é uma variável binária que indica se a sonda s faz parte da rota r . Se for igual a 1, faz parte. Caso contrário, não. Destaque-se que as rotas não serão necessariamente iguais nos dois períodos;

- $r_{1,s,p}$ é uma variável de decisão criada de forma a forçar o atendimento das restrições de não-antecipatividade para cada sonda no primeiro período (nas seções seguintes será detalhado o uso dessas variáveis).
- $r_{2s,p,i}$ são variáveis de decisão criadas de forma a forçar o atendimento das restrições de não-antecipatividade para cada sonda no segundo período. O índice i se refere a um grupo de cenários para um produto para o qual tem de ser tomada uma única decisão;
- $r_{3,i}$ são variáveis de decisão criadas de forma a forçar o atendimento das restrições de não-antecipatividade para cada rota no segundo período. O índice i se refere a um grupo de cenários para o qual tem de haver o mesmo número de rebocadores por rota;
- $reb_{r,t,c}$ é uma variável inteira que indica o número de rebocadores que deve ser usado na rota r , no período t e no cenário c ;
- $dist_r$ é a distância total percorrida pela rota r .

Ressalte-se que todas as variáveis e parâmetros são maiores ou iguais a zero.

A função objetivo e as restrições dos modelos, o primeiro sem roteamento e o segundo com roteamento, são descritas nas seções seguintes. No capítulo V, serão detalhados os diversos métodos usados na resolução do problema.

IV.2. – Modelo sem Roteamento

IV.2.1 – Função Objetivo

A função objetivo inclui o somatório de custos em todos os períodos e cenários (sendo P_c a probabilidade de cada cenário ocorrer), que podem ser divididos em:

- o custo de estocagem total (cit) nas sondas (como o espaço e o peso que podem ser transportados na sonda são limitados, deve ser computado um custo de estocagem) que é proporcional a um custo de estocagem por produto ($CI_{s,p}$). Considera-se que o custo de estoque é o mesmo por unidade de produto:

$$cit = \sum_s \sum_p \sum_t \sum_c i_{s,p,t,c} CI_{s,p} P_c \quad (4.1)$$

- o custo de falta total (cft) de todos os produtos nas sondas que é muito alto por levar a tempo de sonda parada (a taxa diária de sonda pode ultrapassar os U\$500.000 por dia). Esse custo esperado é igual ao custo de sonda parada (cf_s) multiplicado pela variável binária ($y_{1,s,t,c}$), cujo valor é um quando há falta de pelo menos um produto em um cenário e zero quando não falta nenhum dos dois produtos em um cenário, e pela probabilidade de ocorrência de cada cenário.

$$cft = \sum_s \sum_t \sum_c (y_{1,s,t,c}) cf_s P_c \quad (4.2)$$

O cálculo da variável de decisão binária $y_{1,s,t,c}$ depende da variável $y_{2,s,p,t,c}$, cujo cálculo será explicado na seção de restrições de balanço de massa. Para tanto, usa-se a seguinte regra lógica:

$$\begin{aligned} &se \quad y_{2,s,1,t,c} = 0 \text{ ou } y_{2,s,2,t,c} = 0; \\ &então: \quad y_{1,s,t,c} = 1 \end{aligned} \quad (4.3)$$

Baseando-se em Bisschop (2012), essa restrição lógica pode ser transformada em restrições linear por meio das seguintes equações:

$$\sum_p (1 - y_{2,s,p,t,c}) \geq y_{1,s,t,c} \quad \forall s,t,c \quad (4.4)$$

Por meio da equação 4.4 sempre que a demanda não-atendida dos dois produtos em uma sonda em dado período em um dado cenário for zero, então y_2 será zero.

$$\sum_p (1 - y_{2,s,p,t,c}) \leq y_{1,s,t,c} \cdot UL_1 \quad \forall s,t,c \quad (4.5)$$

Já a equação 4.5 faz que quando houver demanda não-atendida de pelo menos um produto, y_2 será um.

- os custos de transporte totais esperados ($cttr$) de produtos dos portos às sondas que são iguais a distância do porto à sonda ($Dist_{s,t}$) multiplicada por uma constante por unidade de distância (CT), pela probabilidade de cada cenário e pela quantidade transportada ($tr_{s,p,t,c}$).

$$cttr = CT \sum_s \sum_p \sum_t \sum_c (tr_{s,p,t,c} Dist_{s,t} P_c) \quad (4.6)$$

- os custos totais (cst) de se manter estoques abaixo do estoque de segurança (IS). Estes custos têm por objetivo tentar evitar faltas de produtos nas sondas e podem ser calculados por:

$$cst = \sum_s \sum_p \sum_t \sum_c CS_{s,p} (IS_{s,p} - i_{s,p,t,c}) P_c \quad \forall (IS_{s,p} - i_{s,p,t,c}) > 0 \quad (4.7)$$

O parâmetro $CS_{s,p}$ representa o custo unitário por se manter estoque do produto p abaixo do estoque de segurança na sonda s . O termo $((IS_{s,p} - i_{s,p,t,c}) > 0)$ precisa ser

transformado para ser usado em programação linear por meio das seguintes equações lineares:

$$IS_{s,p} - i_{s,p,t,c} \leq w_{s,p,t,c} \quad \forall s, p, t, c \quad (4.8)$$

$$w_{s,p,t,c} \geq 0 \quad (4.9)$$

Assim quando houver estoque abaixo do estoque de segurança, a variável $w_{s,p,t,c}$ será estritamente positiva. Logo, o termo cst será:

$$cst = \sum_s \sum_p \sum_t \sum_c CS_s w_{s,p,t,c} P_c \quad (4.10)$$

Em suma, w é uma variável que indica o estoque necessário para se alcançar o estoque de segurança, assumindo valores estritamente positivos apenas quando o estoque for menor que o nível de segurança.

- por fim, foi contabilizado um custo de excesso de estoque ($ciet$) que consiste no caso de uma sonda estar com estoque grande o suficiente para impossibilitar o desembarque de todos os produtos transportados do rebocador para a sonda. Neste caso o rebocador se destina ao próximo ponto de parada para depois retornar a sonda. Esse custo pode ser representado pela seguinte equação:

$$ciet = CR \sum_s \sum_t \sum_c y_{3,s,t,c} P_c \quad (4.11)$$

Na maioria dos casos, esse custo tende a ser zero, mas pode ser necessário para evitar o risco da existência de restrições de limitação de peso inviáveis principalmente na determinação do EEV, já que, no cálculo desse valor, as quantidades a serem transportadas são parâmetros, conforme será detalhado no capítulo V, e como em métodos de Monte Carlo com número de cenários elevado

podem ocorrer demandas bem abaixo da média, ou seja, poderia haver inviabilidade de algumas restrições de capacidade de peso se não houvesse uma variável de folga como y_3 .

Além disso, esse custo representa um problema real nas sondas que força o rebocador a retornar à sonda. O coeficiente CR representa o custo de retorno do rebocador à sonda e foi estimado em uma diária do rebocador. Esse valor é mais alto que o tempo real (algo em torno de seis a oito horas) mas considerando os problemas operacionais causados por esse retorno usou-se um fator de punição de um dia.

Logo, a função objetivo ($f.o.$) será:

$$f.o. = \min (cit + cft + ctr + cst + ciet) \quad (4.12)$$

IV.2.2 – Balanço de Massa

Há duas equações que representam o balanço de massa.

A primeira equação é a base do balanço de massa: a quantidade transportada de cada produto para cada sonda mais o estoque em $t-1$ e mais a demanda não-atendida é igual a demanda de cada produto em cada sonda mais o estoque o estoque no período t mais a demanda não-atendida no período $t-1$:

$$tr_{s,p,t,c} + i_{s,p,t-1,c} + dn_{s,p,t,c} = DE_{s,p,t,c} + i_{s,p,t,c} + dn_{s,p,t-1,c} \quad \forall s,p,t,c \quad (4.13)$$

Ressalte-se que no período inicial o estoque é dado, passando a ser uma variável de decisão no período seguinte.

A segunda equação representa uma restrição não-linear. Essa restrição se baseia no fato de que a existência de estoque em t implica o atendimento de toda a

demanda (se $i_{s,p,t,c} > 0$, $dn_{s,p,t,c} = 0$) e de que o contrário também é válido (se $dn_{s,p,t,c} \geq 0$, $i_{s,p,t,c} = 0$). Essa relação pode ser expressa pela restrição abaixo:

$$dn_{s,p,t,c} i_{s,p,t,c} = 0 \quad \forall s, p, t, c \quad (4.14)$$

Em suma, uma das duas variáveis é igual a zero.

Para se linearizar a equação 4.14, primeiro deve-se transformá-la nas seguintes restrições:

$$\begin{aligned} & \text{se } dn_{s,p,t,c} > 0, \\ & \text{então: } i_{s,p,t,c} = 0 \end{aligned} \quad (4.15)$$

e

$$\begin{aligned} & \text{se } i_{s,p,t,c} > 0, \\ & \text{então: } dn_{s,p,t,c} = 0 \end{aligned} \quad (4.16)$$

Conforme indicado por Bisschop (2012) esse tipo de restrições pode ser transformada nas seguintes restrições lineares:

$$dn_{s,p,t,c} \geq \varepsilon - LL y_{2,s,p,t,c} \quad \forall s, p, t, c \quad (4.17)$$

$$i_{s,p,t,c} \leq UL_2 y_{2,s,p,t,c} \quad \forall s, p, t, c \quad (4.18)$$

$$i_{s,p,t,c} \geq \varepsilon - LL(1 - y_{2,d,p,t,s}) \quad \forall s, p, t, c \quad (4.19)$$

$$dn_{s,p,t,c} \leq UL_2(1 - y_{2,s,p,t,c}) \quad \forall s, p, t, c \quad (4.20)$$

Sendo que y_2 é uma variável de decisão binária e LL e UL_2 são constantes que representam limites inferiores e superiores respectivamente suficientemente grandes

para que as equações 4.17 e 4.18 não sejam ativas quando y_2 for igual a 1 e para que as restrições 4.19 e 4.20 não sejam ativas quando y_2 for igual a zero.

Como todas as variáveis e parâmetros do problema são maiores ou iguais a zero, basta que LL seja igual a ε .

IV.2.3 – Limitações de Peso

Em cada sonda, há uma limitação física que pode ser tanto por volume quanto por massa. No caso, foi considerada restrição por massa (M_p é a massa do produto p) de modo que há um limite máximo de estocagem de produtos por sonda ($M \max_s$):

$$\sum_p M_p (tr_{s,p,t,c} + i_{s,p,t-1,c} - DE_{s,p,t,c}) \leq M \max_s + y_{3,s,t,c} UL_2 \quad \forall s,t,c \quad (4.21)$$

Sendo UL_2 , um limite superior que garante o atendimento da restrição quando a variável binária y_3 for igual a 1.

IV.2.4 – Restrições de Não-Antecipatividade

Essas restrições são formuladas para garantir a existência de incerteza no processo de decisão:

$$tr_{s,p,1,c} = r_{1,s,p} \quad \forall s,p \text{ para o } 1^\circ \text{ período} \quad (4.22)$$

$$tr_{s,p,2,c} = r_{2,s,p,i}, \quad \forall s,p \text{ para o } 2^\circ \text{ período para cada grupo de cenários } i \quad (4.23)$$

Essas restrições serão detalhadas no capítulo V. Seguem abaixo todas as equações definitivas do modelo:

$$f.o. = \min (cit + cft + cctr + cst + ciet) \quad (4.12)$$

$$cit = \sum_s \sum_p \sum_t \sum_c i_{s,p,t,c} CI_{s,p} P_c \quad (4.1)$$

$$cft = \sum_s \sum_t \sum_c (y_{1,s,t,c}) cf_s P_c \quad (4.2)$$

$$\sum_p (1 - y_{2,s,p,t,c}) \geq y_{1,s,t,c} \quad \forall s, t, c \quad (4.4)$$

$$\sum_p (1 - y_{2,s,p,t,c}) \leq y_{1,s,t,c} \cdot UL_1 \quad \forall s, t, c \quad (4.5)$$

$$cctr = CT \sum_s \sum_p \sum_t \sum_c (tr_{s,p,t,c} Dist_{s,t} P_c) \quad (4.6)$$

$$IS_{s,p} - i_{s,p,t,c} \leq w_{s,p,t,c} \quad \forall s, p, t, c \quad (4.8)$$

$$w_{s,p,t,c} \geq 0 \quad (4.9)$$

$$cst = \sum_s \sum_p \sum_t \sum_c CS_s w_{s,p,t,c} P_c \quad (4.10)$$

$$ciet = CR \sum_s \sum_t \sum_c y_{3,s,t,c} P_c \quad (4.11)$$

$$tr_{s,p,t,c} + i_{s,p,t-1,c} + dn_{s,p,t,c} = DE_{s,p,t,c} + i_{s,p,t,c} + dn_{s,p,t-1,c} \quad \forall s, p, t, c \quad (4.13)$$

$$dn_{s,p,t,c} \geq \varepsilon - LL y_{2,s,p,t,c} \quad \forall s, p, t, c \quad (4.17)$$

$$i_{s,p,t,c} \leq UL_2 y_{2,s,p,t,c} \quad \forall s, p, t, c \quad (4.18)$$

$$i_{s,p,t,c} \geq \varepsilon - LL(1 - y_{2,d,p,t,s}) \quad \forall s, p, t, c \quad (4.19)$$

$$dn_{s,p,t,c} \leq UL_2(1 - y_{2,s,p,t,c}) \quad \forall s, p, t, c \quad (4.20)$$

$$\sum_p M_p (tr_{s,p,t,c} + i_{s,p,t-1,c} - DE_{s,p,t,c}) \leq M \max_s + y_{3,s,t,c} UL_2 \quad \forall s, t, c \quad (4.21)$$

$$tr_{s,p,1,c} = r_{1,s,p} \quad \forall s, p \text{ para o } 1^\circ \text{ período} \quad (4.22)$$

$$tr_{s,p,2,c} = r_{2,s,p,i}, \quad \forall s, p \text{ para o } 2^\circ \text{ período para cada grupo de cenários } i \quad (4.23)$$

IV.3 – Modelo com Roteamento

No roteamento, serão definidas as rotas percorridas por cada barco de suprimento. No modelo essa informação é contida na variável $y_{r,s,t}$ que é uma variável binária que tem valor 1 quando a sonda s faz parte da rota r .

Abaixo serão apresentadas as mudanças na formulação do modelo com roteamento.

No modelo com roteamento, as principais diferenças são: o cálculo dos custos de transporte, as restrições de capacidade de armazenamento por rebocador, as restrições de número máximo de rebocadores e as restrições de roteamento. As demais equações e restrições permanecem as mesmas.

A restrição de capacidade é dada pela equação:

$$\sum_s \sum_p (tr_{s,p,t,c} \cdot y_{r,s,t}) \leq reb_{r,t,c} \cdot CapPSV \quad \forall r,t,c \quad (4.24)$$

O número total de rebocadores usados não pode exceder o número total de rebocadores disponível:

$$\sum_r reb_{r,t,c} \leq Re bT \quad \forall t,c \quad (4.25)$$

Para fazer o roteamento, impõe-se a condição de que cada sonda seja atendida apenas por uma rota:

$$\sum_r y_{r,s,t} = 1 \quad \forall s,t \quad (4.26)$$

Há restrições de não-antecipatividade para o roteamento também:

$$reb_{r,2,s} = r_{3,i} \quad \forall s,p \quad \text{para o } 2^\circ \text{ período e para cada grupo de cenários } i \quad (4.27)$$

Já custo de transporte total será dado por:

$$cttr = \frac{CReb}{VM \cdot CoefSeg} \sum_r \sum_t \sum_c (dist_r \cdot reb_{r,t,c}) \cdot P_c + CRebOc \cdot \sum_t (RebT - \sum_r \sum_c reb_{r,t,c} P_c) \quad (4.28)$$

O custo de transporte total passa a ser distribuído entre os rebocadores que estão sendo usados ($reb_{r,t,c}$) e os ociosos ($RebT - reb_{r,t,c}$). Seguem as equações definitivas do modelo com roteamento:

$$f.o. = \min (cit + cft + cttr + cst + ciet) \quad (4.12)$$

$$cit = \sum_s \sum_p \sum_t \sum_c i_{s,p,t,c} CI_{s,p} P_c \quad (4.1)$$

$$cft = \sum_s \sum_t \sum_c (y_{1,s,t,c}) cf_s P_c \quad (4.2)$$

$$\sum_p (1 - y_{2,s,p,t,c}) \geq y_{1,s,t,c} \quad \forall s, t, c \quad (4.4)$$

$$\sum_p (1 - y_{2,s,p,t,c}) \leq y_{1,s,t,c} \cdot UL_1 \quad \forall s, t, c \quad (4.5)$$

$$cttr = \frac{CReb}{VM \cdot CoefSeg} \sum_r \sum_t \sum_c (dist_r \cdot reb_{r,t,c}) \cdot P_c + CRebOc \cdot \sum_t (RebT - \sum_r \sum_c reb_{r,t,c} P_c) \quad (4.28)$$

$$IS_{s,p} - i_{s,p,t,c} \leq w_{s,p,t,c} \quad \forall s, p, t, c \quad (4.8)$$

$$w_{s,p,t,c} \geq 0 \quad (4.9)$$

$$cst = \sum_s \sum_p \sum_t \sum_c CS_s w_{s,p,t,c} P_c \quad (4.10)$$

$$ciet = CR \sum_s \sum_t \sum_c y_{3,s,t,c} P_c \quad (4.11)$$

$$tr_{s,p,t,c} + i_{s,p,t-1,c} + dn_{s,p,t,c} = DE_{s,p,t,c} + i_{s,p,t,c} + dn_{s,p,t-1,c} \quad \forall s, p, t, c \quad (4.13)$$

$$dn_{s,p,t,c} \geq \varepsilon - LL y_{2,s,p,t,c} \quad \forall s, p, t, c \quad (4.17)$$

$$i_{s,p,t,c} \leq UL_2 y_{2,s,p,t,c} \quad \forall s, p, t, c \quad (4.18)$$

$$i_{s,p,t,c} \geq \varepsilon - LL(1 - y_{2,d,p,t,s}) \quad \forall s, p, t, c \quad (4.19)$$

$$dn_{s,p,t,c} \leq UL_2(1 - y_{2,s,p,t,c}) \quad \forall s, p, t, c \quad (4.20)$$

$$\sum_p M_p (tr_{s,p,t,c} + i_{s,p,t-1,c} - DE_{s,p,t,c}) \leq M \max_s + y_{3,s,t,c} UL_2 \quad \forall s, t, c \quad (4.21)$$

$$tr_{s,p,1,c} = r_{1,s,p} \quad \forall s, p \text{ para o } 1^\circ \text{ período} \quad (4.22)$$

$$tr_{s,p,2,c} = r_{2,s,p,i} \quad \forall s, p \text{ para o } 2^\circ \text{ período para cada grupo de cenários } i \quad (4.23)$$

$$\sum_s \sum_p (tr_{s,p,t,c} \cdot y_{r,s,t}) \leq reb_{r,t,c} \cdot CapPSV \quad \forall r, t, c \quad (4.24)$$

$$\sum_r reb_{r,t,c} \leq Rebt \quad \forall t,c \quad (4.25)$$

$$\sum_r y_{r,s,t} = 1 \quad \forall s,t \quad (4.26)$$

$$reb_{r,2,s} = r_{3,i} \quad \forall s,p \text{ para o 2}^\circ \text{ período e para cada grupo de cenários } i \quad (4.27)$$

V – MÉTODOS DE RESOLUÇÃO: ABORDAGENS ESTOCÁSTICAS E ROTEIRIZAÇÃO

Nesse capítulo, são apresentados os métodos de resolução usados para a resolução do modelo estocástico e ao algoritmo de resolução para o modelo com roteamento.

V.1 – Abordagens Estocásticas

Uma vez que o problema estocástico não possui uma solução analítica, assim como grande parte dos problemas de programação estocástica (Birge e Louveaux (2012)), várias abordagens foram feitas conforme descrito nas subseções a seguir:

V.1.1 – Modelo Discretizado

Foram formulados cenários discretizados que representam a distribuição de probabilidade de áreas da distribuição contínua para enumerar os cenários conforme descrito abaixo.

Para o caso dos produtos químicos foi discretizada a distribuição de probabilidade em três cenários (número mínimo para avaliar a importância de modelos com incerteza, para mais detalhes ver Keefer (1994)) para todas as sondas:

- baixa demanda que condensa a demanda entre zero e um terço, sendo usado o ponto médio de um sexto da probabilidade;

- média demanda que condensa a demanda entre um terço e dois terços, sendo usado o ponto médio de três sextos da probabilidade;
- alta demanda que condensa a demanda entre dois terços e três terços, sendo usado o ponto médio de cinco sextos da probabilidade;

Foi considerado que o parâmetro de probabilidades seria o mesmo nos dois períodos. Já a demanda de tubos, conforme detalhado no capítulo VI, foi tratada como uma binomial com probabilidade de 0,7 de haver demanda.

As demandas dos dois produtos também são consideradas independentes entre si.

Foram criados cenários 36 cenários. Para o produto 1 (produtos químicos) são 9 cenários e para o produto 2 (tubos) são 4 cenários. Pela hipótese de independência, são então tratados 36 cenários. Assim para cada uma das nove possibilidades de realização de demanda do produto 1 criam-se quatro cenários para cada uma das possibilidades de realização de demanda do produto 2.

Para ilustrar os cenários, segue na figura V.1 a árvore de decisão de dois períodos para produtos químicos:

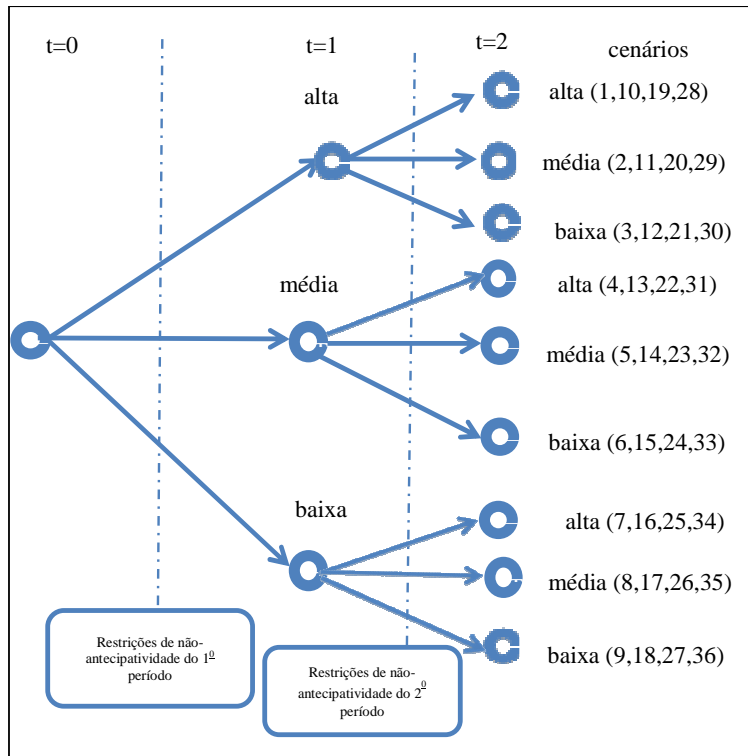


Figura V.1 – Árvore de decisão para produtos químicos

Abaixo na figura V.2, segue a árvore de decisão para os tubos:




Figura V.2 – Árvore de decisão para tubos

Para impedir que as decisões sejam tomadas sob condições de informação perfeita, foram acrescentadas as restrições de não-antecipatividade.

Para o primeiro período, usa-se o seguinte conjunto de restrições:

$$tr_{s,p,1,c} = r_{1,s,p} \quad \forall s,p \quad (5.1)$$

Essas restrições fazem que possa ser tomada apenas uma decisão no primeiro período e, não, uma decisão para cada cenário, o que corresponderia a um modelo sem incerteza.

Para o segundo período, o número de restrições é maior:

$$\begin{aligned} tr_{s,1,2,c} &= r_{2,s,1_1} && \text{para } c \in C_{1_1} = \{1,2,3,10,11,12,19,20,21,28,29,30\} \text{ e } \forall s \\ tr_{s,1,2,c} &= r_{2,s,1_2} && \text{para } c \in C_{1_2} = \{4,5,6,13,14,15,22,23,24,31,32 \text{ e } 33\} \text{ e } \forall s \\ tr_{s,1,2,c} &= r_{2,s,1_3} && \text{para } c \in C_{1_3} = \{7,8,9,16,17,18,25,26,27,34,35 \text{ e } 36\} \text{ e } \forall s \\ tr_{s,2,2,c} &= r_{2,s,2_1} && \text{para } c \in C_{2_1} = \{1,2,\dots,18\} \text{ e } \forall s \\ tr_{s,2,2,c} &= r_{2,s,2_2} && \text{para } c \in C_{2_2} = \{19,20,\dots,36\} \text{ e } \forall s \end{aligned} \quad (5.2)$$

Para mensurar o valor da estocasticidade no modelo foram calculados o RP, o WS, o EV e o EEV (valor esperado da solução determinística). Em função desses, foi calculado o EVPI e o VSS.

O EEV foi calculado de forma um pouco diferente da formulada na literatura, já que o modelo proposto nesse trabalho difere do modelo estocástico de dois estágios, pois enquanto no modelo clássico apenas a variável de primeiro estágio é tomada em condições de incerteza, no modelo desse trabalho nos dois períodos há decisões tomadas sob incerteza.

Assim, para a determinação do EEV, calculou-se o valor ótimo de $tr_{s,p,t,c}$ para o modelo determinístico. Em seguida, esses valores foram inseridos como *input*, ou seja,

deixaram de ser variáveis e viraram parâmetros no modelo estocástico discretizado e foram obtidos os valores ótimos do EEV.

Ressalte-se que nesse modelo a decisão básica é de checar cada restrição de balanço de massa e verificar se cada uma delas será satisfeita com a adição de estoque ou de demanda não-atendida.

Para o modelo discretizado com roteamento foi necessário acrescentar outro grupo de restrições de não-anticipatividade, já que o número de rebocadores atuando em cada rota ($reb_{r,t,c}$) depende de seis possibilidades de realização do primeiro período:

- grupo de cenários 1: ocorre quando a demanda de produtos químicos for alta e quando houver realização de demanda de tubos, consiste nos cenários 1, 2, 3, 10, 11 e 12;
- grupo de cenários 2: ocorre quando a demanda de produtos químicos for alta e quando não houver realização de demanda de tubos, consiste nos cenários 19, 20, 21, 28, 29 e 30;
- grupo de cenários 3: ocorre quando a demanda de produtos químicos for média e quando houver realização de demanda de tubos, consiste nos cenários 4, 5, 6, 13, 14 e 15;
- grupo de cenários 4: ocorre quando a demanda de produtos químicos for média e quando não houver realização de demanda de tubos, consiste nos cenários 22, 23, 24, 31, 32 e 33;
- grupo de cenários 5: ocorre quando a demanda de produtos químicos for baixa e quando houver realização de demanda de tubos, consiste nos cenários 7, 8, 9, 16, 17 e 18;

- grupo de cenários 6: ocorre quando a demanda de produtos químicos for baixa e quando não houver realização de demanda de tubos, consiste nos cenários 25, 26, 27, 34, 35 e 36.

Essas restrições podem ser representadas pelo seguinte conjunto de equações:

$$\begin{aligned}
reb_{r,2,c} &= r_{3,1} && \text{para } c \in C_1 = \{1,2,3,10,11,12\} \text{ e } \forall r \\
reb_{r,2,c} &= r_{3,2} && \text{para } c \in C_2 = \{19,20,21,28,29,30\} \text{ e } \forall r \\
reb_{r,2,c} &= r_{3,3} && \text{para } c \in C_3 = \{4,5,6,13,14,15\} \text{ e } \forall r \\
reb_{r,2,c} &= r_{3,4} && \text{para } c \in C_4 = \{22,23,24,31,32,33\} \text{ e } \forall r \\
reb_{r,2,c} &= r_{3,5} && \text{para } c \in C_5 = \{7,8,9,16,17,18\} \text{ e } \forall r \\
reb_{r,2,c} &= r_{3,6} && \text{para } c \in C_6 = \{25,26,27,34,35,36\} \text{ e } \forall r
\end{aligned} \tag{5.3}$$

V.1.2 – Modelo com *Sample Approximation Average* (SAA)

Para a resolução por SAA, as restrições de não-antecipatividade do segundo período foram similares às do primeiro período, já que como o modelo não é discretizado não há nós pré-definidos ao final do primeiro período. Ou seja, no modelo SAA, a quantidade transportada não é indexada pelo cenário ($tr_{s,p,t}$).

Definiu-se um cenário como a realização de uma variável aleatória para cada sonda, para cada produto, para cada período. Assim, cada cenário envolveu a realização de 40 variáveis aleatórias. Consideraram-se os cenários equiprováveis, ou seja, se o número de cenários for n , a probabilidade de cada cenário é $1/n$.

Para a obtenção de limites inferiores e superiores foi usada a metodologia proposta por Shapiro e Homem-de-Mello (2001), explicada na seção II.7, que sugere o uso de um número a de amostras de tamanho n para a obtenção de um intervalo de

confiança para a obtenção de um limite inferior com um nível α de significância. Para a obtenção de um limite superior é sugerido o seguinte procedimento:

1. o uso de estimadores não-enviesados, o mais comum é o uso de estimadores obtidos por Monte Carlo;
2. Em seguida, com esses estimadores são obtidos os valores da função objetivo para amostras diferentes de n cenários gerados por Monte Carlo, obviamente o resultado obtido será acima do ótimo e constituirá um limite superior com um nível α de significância.

V.1.3. – Modelo com *Latin Hypercube Sampling* (LHS)

Com o intuito de tentar obter método de amostragem que obtivesse menores variâncias, foi utilizado o LHS, para mais detalhes ver Homem-de-Mello e Bayraksan (2013). A função de distribuição de probabilidades dos produtos químicos foi dividida em 5 espaços cada um contendo um quinto da função de distribuição de probabilidade da demanda. Em cada um desses espaços foi usada a função de distribuição de probabilidade considerada mais adequada (a escolha da função de distribuição de probabilidade será detalhada no capítulo VI). Em suma, há a realização de dois sorteios para a demanda de produtos químicos de cada sonda em dado período:

- um para determinar em qual quinto da função de distribuição de probabilidade da demanda será escolhida a amostra, ou seja, é um sorteio aleatório discreto com 5 resultados equiprováveis;
- sendo n o valor selecionado aleatoriamente no primeiro sorteio, em seguida sorteia-se um valor de uma distribuição contínua uniforme distribuída no intervalo $[(n-1)/5 ; n/5]$ e usa-se uma função inversa da função de distribuição de probabilidade de demanda para determinar o valor que será usado.

Para a demanda de tubos, continuam sendo feitos sorteios aleatórios de uma binomial com 0,7 de probabilidade de realização de demanda.

Para que pudessem ser usados os testes clássicos de intervalo de confiança usados no SAA, foram geradas 3 amostras aleatórias de cada demanda de produtos químicos por sonda, por período e foi usado o valor médio das demandas. Caso não seja adotado esse procedimento, as amostras não são independentes, e, por consequência, o teorema clássico do limite central não é válido (Shapiro et al. (2009)).

V.1.4. – Modelo para obtenção de limites superiores

Com o intuito de estabelecer limites superiores, o problema foi solucionado para diversos níveis de probabilidade altos (todos acima de 80%) de realização da demanda estocástica, sendo que para cada nível de probabilidade considerou-se que o valor da demanda de cada sonda por produtos químicos foi igual ao nível de probabilidade associado. Por exemplo, para o valor de 80% de probabilidade, usa-se o valor da demanda que corresponde a esse valor da função distribuição de probabilidade. Já para os tubos, que seguem uma distribuição binomial, considerou-se a ocorrência de demanda para todas as sondas em todos os períodos.

V.1.5. – Modelo com resolução por redução de cenários

Dados os tempos computacionais elevados para modelos com muitos cenários e os problemas associados à falta de memória RAM, considerou-se que poderia ser adequado o uso de técnicas de redução ótima de número de cenários (Dupacova et al. (2003)).

Foram gerados cenários discretizados da seguinte forma:

- a demanda por produtos químicos foi discretizada em 100 cenários cada um deles com um por cento de probabilidade para todas as sondas e para os dois períodos, sendo usado o ponto médio de cada intervalo. Assim, o primeiro intervalo tem como valor 0,5% para todas as sondas e para os dois períodos, o segundo, 1,5% e assim sucessivamente, até o último, 99,5%;
- a demanda por tubos foi discretizada em quatro cenários para todas as sondas conforme ilustrado abaixo:




Figura V.3 – Árvore de decisão para os tubos no método de redução de cenários

Por fim, multiplicando-se o número de cenários dos produtos químicos com o número de cenários dos tubos, chega-se ao número de 400 cenários de modo que o primeiro cenário corresponde ao caso em que as demandas por produtos químicos correspondem ao ponto médio de 0,5% e há realização de demanda de tubos nos dois períodos. Já o segundo cenário corresponde ao ponto médio de 0,5% e há realização

de demanda de tubos apenas no primeiro período. O terceiro cenário corresponde ao ponto médio de 0,5% e há realização de demanda de tubos apenas no segundo período. O quarto cenário corresponde ao ponto médio de 0,5% e não há realização de demanda de tubos em nenhum período. No quinto cenário, as demandas por produtos químicos correspondem ao ponto médio de 1,5% e há realização de demanda de tubos nos dois períodos. Segue-se dessa forma até o último cenário.

Essa definição dos cenários foi feita de forma a possibilitar a resolução do problema com todos os cenários em um limite de tempo elevado e fazer a posterior comparação com os resultados obtidos com o algoritmo de redução de cenários.

O algoritmo de redução de cenários adotado foi o de *backward reduction* baseado em Heitsch e Romisch (2003). Usou-se o algoritmo de backward induction e, não, o de *forward induction* pois aquele costuma apresentar resultados melhores quando o número de cenários excluídos é maior do que 25% (Heitsch e Romisch (2003)).

O algoritmo de *backward induction* foi implementado da seguinte forma:

Passo 1_gera-se a matriz de custos $C_{N \times N}$, sendo N o número inicial de cenários e cada elemento da matriz é calculado da seguinte forma:

$$c(n, nl) = \sum_s \sum_p \sum_t \text{abs}(DE_{s,p,t,n} - DE_{s,p,t,nl}) \quad \forall n=1, \dots, N \wedge \forall nl=1, \dots, N \quad (5.4)$$

A matriz leva em consideração o valor absoluto da soma das diferenças entre as realizações das demandas.

Passo 2_acha-se o mínimo de cada linha da matriz $C_{N \times N}$:

$$c(n, j^*) = \min_j(c(n, j)) \quad \forall n=1, \dots, N \wedge \forall j=1, \dots, N \quad (5.5)$$

Passo 3_multiplica-se $c(n, j^*)$ pela probabilidade de cada cenário n e acha-se o mínimo:

$$c(l^*, j^*) = \min_n (prob(n) \times c(n, j^*)) \quad \forall n = 1, \dots, N \quad (5.6)$$

O cenário l^* será o primeiro a ser excluído.

Passo 4_faz-se a redistribuição de probabilidade do cenário que excluído:

$$prob(j^*) = prob(j^*) + prob(l^*) \quad (5.7)$$

Passo 5_elimina-se a linha e a coluna l^* da matriz C de modo que ela passa a ser uma matriz quadrada com uma linha e uma coluna a menos.

Passo 6_repetir passos 2 a 5 até que seja eliminado o número de cenários desejado.

V.2 – Algoritmo usado para roteamento

Para fazer o roteamento das sondas foi adaptado o algoritmo de Gillett e Miller (1974) da seguinte forma:

Passo 1: Tendo como origem as coordenadas do porto de Macaé, derivaram-se as coordenadas x e y das sondas nos dois períodos;

Passo 2: Considerou-se que as sondas posicionadas nos dois primeiros quadrantes seriam positivas e as no terceiro e quarto quadrantes seriam negativas,

para depois calcular-se a posição de cada uma das sondas para cada um dos períodos em radianos, ou seja, a contagem foi de $-\pi$ a π ;

Passo 3: Ordenaram-se as sondas em ordem decrescente de radianos. O objetivo de fazer o ordenamento dessa maneira foi evitar o transporte na parte terrestre, que obviamente não pode ocorrer;

Passo 4: Calculou-se a demanda média da soma dos dois produtos de cada sonda por período ($demMédia(s,t)$);

Passo 5: Inicia-se o roteamento pelo vértice não-roteado (sonda) na posição com mais radianos em cada período, e são adicionados os vértices com mais radianos até que a soma das demandas médias dos vértices não exceda a capacidade livre do rebocador ($CapPSV$). Quando a capacidade do rebocador for excedida, inicia-se uma nova rota e repete-se o procedimento até que todos os vértices estejam roteados;

Passo 6: Por fim, calculam-se as distâncias percorridas em cada rota, em cada período.

Com o intuito de se testar a influência do sentido no roteamento, testou-se também o algoritmo de roteamento com ordem crescente de radianos, isto é, o passo 3 foi alterado.

VI – CASO DE APLICAÇÃO

Os dados foram baseados nas operações *offshore* da Petrobras na Bacia de Campos em 2011 e alguns parâmetros foram estimados baseados na opinião de experts. A função de distribuição de probabilidade dos produtos foi fundamentada nos resultados de testes estatísticos de aderência.

Os modelos descritos foram rodados em um computador intel corei7, com 8GB de memória RAM no software AIMMS versão 3.13, sendo usado como solver o GUROBI versão 5.0.

VI.1 – Dados

Como base de dados, foram usados dados de quantidades transportadas em metro quadrado por *Platform Supply Vessels* (P.S.V.) para dez sondas de perfuração (nove semi-submersíveis e um navio-sonda, que foram denominadas de S1 a S10) na Bacia de Campos no período de 8 de março de 2011 a 27 de setembro de 2011 para a modelagem do problema, totalizando um período de trinta semanas. A seguir serão descritos os critérios e métodos usados na determinação dos parâmetros e nas funções de distribuição de probabilidade das variáveis estocásticas.

VI.1.1 – Distância

Por meio das coordenadas de latitude e longitude de cada sonda em cada período foram calculadas as distâncias (usadas para a determinação do custo de

transporte total) com relação ao porto de Macaé de onde é feito o transporte para as sondas e as plataformas da Bacia de Campos.

VI.1.2 – Parâmetros de Peso

A massa dos dois produtos (M_p) foi normalizada para 1. Já para a determinação do limite máximo de estocagem de produtos por sonda (M_{max_s}), foi usada a seguinte fórmula:

$$M_{max_s} = CoefSeguran\c{c}a \cdot \left(\sum_p M_{\acute{a}x_{s,p}} \right) M_p \quad (6.1)$$

Sendo que *CoefSegurança* é um coeficiente de segurança (foi usado 1,2) e $M_{\acute{a}x_{s,p}}$ é o maior valor do histórico de quantidade transportada por produto por sonda multiplicada por M_p . Tentou-se assim que em condições normais o limite de peso não fosse ultrapassado, ou seja, almeja-se que a restrição de peso seja inativa. Considerou-se, todavia, que sua inclusão era importante para evitar casos em que fossem transportadas quantidades muito grandes em um único período.

VI.1.3 – Parâmetros de Estoque

O estoque inicial $I0_{s,p}$ foi determinado como dez por cento da média da quantidade transportada por produto para cada sonda nos 30 períodos:

$$IO_{s,p} = 0,1 \cdot \frac{\sum_{t=1}^N tr_{s,p,t}}{N} \quad (6.2)$$

Sendo que $N=30$.

O estoque de segurança foi definido como duas vezes o desvio-padrão da série temporal de quantidade transportada por sonda, por produto:

$$IS_{s,p} = 2 \cdot desvp(tr_{s,p,t}) \quad (6.3)$$

Tendo em vista que o desvio-padrão e o valor do estoque de segurança estão relacionados com a variabilidade, faz sentido que o estoque de segurança seja proporcional ao desvio-padrão. Considerou-se que 2 seria um coeficiente de proporcionalidade adequado, visto que no caso de uma distribuição normal padrão cobre mais de 97% da função de distribuição de probabilidade acumulada.

VI.1.4 – Parâmetros de Custo

O custo de estocagem por sonda por produto ($CI_{s,p}$) levou em consideração o custo de estoque nas sondas, ou seja, relacionou-se o valor dos produtos com uma taxa de juros representando os custos de se investir em material não-usado em determinado período, conforme a equação abaixo:

$$CI_{s,p} = in \cdot preço_p \quad (6.4)$$

Sendo que in representa a taxa de juros nominal.

O custo de falta por sonda (CF_s) foi calculado com base na profundidade que a mesma poderia atuar. Para sondas com capacidade de perfurar em águas com lâmina de água (L.D.A.) superior ou igual a 2.000m foi estimado que o custo diário de afretamento era de US\$500.000/ dia e para as outras foi considerado o valor de US\$400.000. Em suma:

$$CF_s = 500.000 \cdot 7 \quad \text{se L.D.A de } S_i \geq 2000\text{m} \quad (6.5)$$

$$CF_s = 400.000 \cdot 7 \quad \text{se L.D.A de } S_i < 2000\text{m} \quad (6.6)$$

Multiplica-se por 7 pois trata-se de custos semanais.

O parâmetro relativo aos custos de transporte (CT) foi calculado com base nos custos por metro quadrado transportado por rebocador multiplicado por dois (representando o trajeto de ida e volta) dividido pela velocidade média do rebocador, pela área ocupada do convés e por um coeficiente de segurança. Desse modo, CT foi obtido por meio da seguinte equação:

$$CT = \frac{2 \cdot CReb}{VM \cdot CapPSV \cdot Coef.seg} \quad (6.7)$$

O custo de rota por rebocador foi estimado de forma semelhante. A diferença consiste na inclusão do termo $dist_r$ no numerador que não é mais multiplicado por dois e na exclusão do termo relativo à área no denominador. Segue a equação abaixo:

$$CReb_r = \frac{CReb \cdot dist_r}{VM \cdot Coef.seg} \quad (6.8)$$

O custo de rebocador ocioso foi estimado, com base em especialistas da área naval, como 80% do gasto com rebocador em movimento, devido à diminuição dos gastos com combustível e diesel que ocorre quando os rebocadores estão fundeados aguardando, conforme a equação abaixo:

$$C_{ReOc} = C_{Reb} \cdot 0,80 \quad (6.9)$$

O parâmetro de custos CS_s foi considerado diretamente proporcional ao custo de sonda parada (na proporção de 5%) e inversamente proporcional ao tempo de transporte dos produtos do porto à sonda (3 dias). Considerou-se assim que 1,6% seria um fator apropriado:

$$CS_s = 0,016 \times CF_s \quad (6.10)$$

VI.2 – Análise das Variáveis Estocásticas

Devido à ausência de dados agregados das variáveis estocásticas do modelo (demanda de produtos químicos e de tubos), foram usados como *proxy* os dados de quantidade transportados consolidados.

VI.2.1 – Distribuição de Probabilidade da Demanda de Produtos Químicos

Para se fazer os testes estatísticos de aderência para as séries de quantidades transportadas das dez sondas, usou-se uma média móvel de cinco semanas, período no qual uma sonda tendia a permanecer em uma dada localização.

Todos os testes foram rodados no programa *Stat:Fit* versão 2. Para todas as séries os parâmetros foram estimados por meio do estimador de máxima verossimilhança. Conforme Mitchell (1971), foram preferidos os testes de Kolmogorov-Smirnov e de Anderson-Darling aos testes qui-quadrado que tendem a fornecer resultados piores para amostras pequenas. Ressalte-se que seria preferível a realização dos testes com amostras maiores, com cerca de cem pontos, mas a especificidade do problema impossibilita a existência de muitos pontos, já que séries maiores (com um número maior de semanas) poderiam refletir características geológicas bem diferentes de modo que se agruparia numa mesma amostra pontos que caracterizam outras funções de distribuição de probabilidade. Considerou-se que apesar do pequeno número de pontos usados nos testes de aderência, esses possuíam características similares pois os poços estavam próximos.

Considerou-se *a priori* que uma distribuição normal truncada (o ponto zero teria uma probabilidade discreta de ocorrência) poderia ser adequada, pois apresenta a média como moda e é simétrica em relação à média (características que podem ser esperadas na demanda por produtos químicos em sondas). Além disso, o uso de médias-móveis tende a aproximar as amostras de uma distribuição normal pelo teorema do limite central.

Assim, quando o p-valor dos testes de aderência da distribuição normal à amostra não foram rejeitados, usou-se a distribuição normal.

Segue tabela com os principais resultados para os testes de aderência dos produtos químicos das sondas:

Tabela VI.1 – Testes de aderência das demandas de produtos químicos

Sondas	Distribuição	Kolmogorov-Smirnov (p-valor)	Anderson-Darling (p-valor)
S1	Normal (13,7 ;5,99)	0,621	0,877
S2	Lognormal(-1,41; 3,61;0,56)	0,312	0,497
S3	Normal (28,99 ;8,03)	0,971	0,976
S4	Normal (11,53; 5,79)	0,632	0,761
S5	Lognormal(5,65 ;2,44;0,69)	0,81	0,813
S6	Normal (30,37; 9,65)	0,803	0,938
S7	Lognormal (16,25; 2,71;1,17)	0,908	0,891
S8	Normal (26,13; 15,96)	0,533	0,438
S9	Lognormal (1,72; 2,93; 1,08)	0,738	0,752
S10	Normal (39,46; 7,33)	0,468	0,342

Para a maioria das amostras a distribuição normal obteve bons p-valores, em amostras nas quais havia uma maior concentração de valores próxima de zero, a distribuição Lognormal apresentou bons resultados (nessas amostras a hipótese de distribuição normal foi rejeitada). Não se usou a distribuição Loglogistic nesses casos pois apesar de os p-valores dos testes de aderência serem bons, a distribuição da curva à direita da média apresentou dispersão acima do razoável.

Segue o gráfico da distribuição normal de produtos químicos obtida para S1 obtida do *Stat:Fit* versão2:

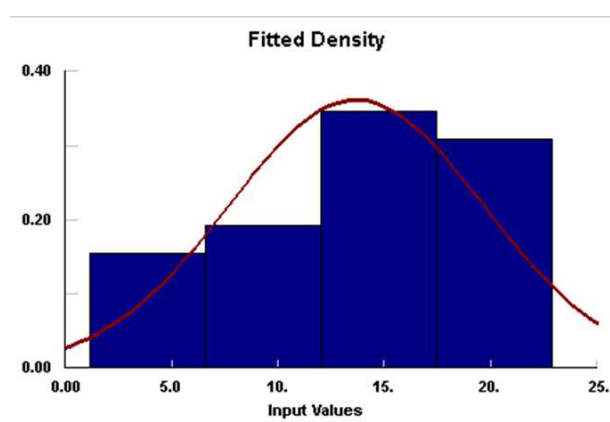


Figura VI.1_Teste de aderência para produtos químicos de S1 (normal)

Como exemplo de gráfico da distribuição Lognormal obtida segue a distribuição de produtos químicos obtida para S2:

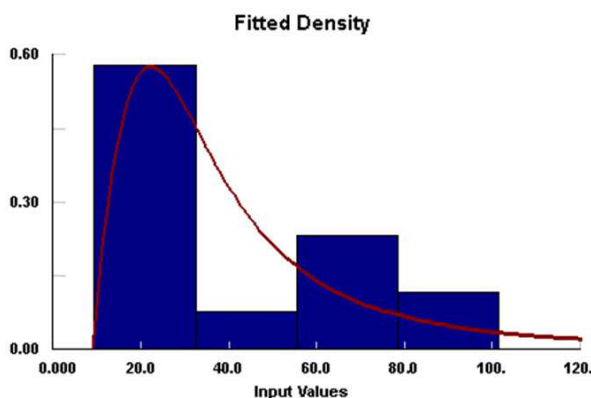


Figura VI.2_Teste de aderência para produtos químicos de S1 (Lognormal)

Nota-se que nas duas distribuições, apenas em um dos quadrantes os dados não se ajustam bem às curvas de distribuição escolhidas.

VI.2.2 – Distribuição de Probabilidade de Demanda de Tubos

Dada a particular característica da entrega de tubos para sondas, em geral é feita uma entrega grande em uma única semana para atender as diversas fases de perfuração de um poço, tornou-se pouco adequado realizar testes de aderência com os dados de transporte.

Após análise das operações e conversas com profissionais envolvidos na operação de sondas, considerou-se adequado o uso de uma distribuição binomial, sendo que a probabilidade de haver demandas por tubos foi estimada em 0,7 por semana para todas as sondas. Para o valor da média dos períodos com demanda, foi usada a média ($\mu_{tub,s}$) dos períodos usados, dividida por P_{tub} , conforme a equação abaixo:

$$\mu_{tub,s} = \frac{\sum_{t=1}^N \text{Histórico}_{s,t}}{P_{tub} \times N} \quad (6.11)$$

Sendo que:

- $\text{Histórico}_{s,t}$ é o valor do histórico da quantidade transportada de tubos pela sonda s no período t ;
- N é o número total de períodos;
- P_{tub} é a probabilidade de haver demanda por tubos.

VI.3 – Resultados dos Métodos de Resolução sem Roteamento

Os modelos sem roteamento foram resolvidos mais rapidamente por serem modelos menores tanto em número de restrições quanto em número de variáveis binárias e inteiras.

VI.3.1 – Resultados do Modelo sem Roteamento Discretizado

Relembrando que:

- cit é custo total esperado de estoques;
- cft é custo total esperado de faltas;
- $cctr$ é o custo total esperado de transporte;
- cst é o custo total esperado de se estar abaixo do estoque de segurança;

- *ciet* é o custo de o barco supridor er de retornar à sonda para descarregar.

Segue a tabela VI.2 com os principais resultados obtidos:

Tabela VI.2_ Resultados do modelo sem roteamento discretizado

Modelo:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>
RP	78.867	0	2.025.369	1.215.588	0	3.319.824
WS	70.816	0	1.727.585	1.255.603	0	3.054.003
EV	70.159	0	1.670.149	1.255.597	0	2.995.904
EEV	373.349	19.451.444	1.655.919	3.153.363,05	0	24.634.076

Pelos resultados, percebe-se que modelos determinísticos, que usam a média em vez de distribuições de probabilidade, apresentam resultados muito ruins pois o custo de falta é muito alto e o modelo determinístico é incapaz de evitar faltas quando a demanda é maior que a média.

Além disso, os tempos de processamento para qualquer um dos modelos foi inferior a 10 segundos.

Tabela VI.3 – EVPI e VSS para o modelo sem roteamento discretizado

EVPI	265.821
VSS	21.314.253

Percebe-se que o EVPI é relativamente baixo mas o VSS é muito alto devido ao alto custo de falta do modelo, ou seja, o valor da inclusão de incertezas no modelo é alto e o valor da informação perfeita é relativamente baixo.

VI.3.2 – Resultados do Modelo sem Roteamento com *Sample Approximation Average* (SAA)

Seguindo a abordagem sugerida por Shapiro e Homem-de-Mello (2001) para a resolução do modelo por SAA, a problema foi inicialmente resolvido para três instâncias com uma amostra com diferentes números de cenários (n) conforme a tabela VI.4:

Tabela VI.4 – Resultados do modelo SAA sem roteamento com 1 amostra

Número de cenários:	Modelo:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>	tempo (s)
50	RP	151.389	0	2.625.192	909.251	0	3.685.831	6,56
	WS	73.631	0	1.842.018	1.239.538	0	3.155.188	3,95
	EV	195.094	0	1.515.677	843.864	0	2.554.635	1,14
	EEV	200.837	22.764.000	1.515.677	893.348	0	25.373.862	1,70
100	RP	155.874	0	2.656.077	884.192	0	3.696.143	24,75
	WS	73.033	0	1.824.290	1.239.370	0	3.136.694	13,99
	EV	195.094	0	1.515.677	843.864	0	2.554.635	1,14
	EEV	201.538	22.071.000	1.515.677	886.037	0	24.674.251	2,25
150	RP	154.643	42.000	2.957.608	865.395	0	3.719.640	79,11
	WS	74.257	0	1.843.339	1.228.499	0	3.146.095	32,1
	EV	195.094	0	1.515.677	843.864	0	2.554.635	1,14
	EEV	202.144	22.418.666	1.515.677	879.961	0	25.016.178	3,43

Em todas as instâncias testadas, o valor do VSS foi considerável e conforme previsto o valor da função objetivo aumentou com o tamanho da amostra já que a estimativa por SAA subestima o valor da função objetivo mas converge assintoticamente, vide Linderoth et al. (2006).

Ressalte-se que com o aumento do tamanho da amostra o *cft* tornou-se estritamente positivo, ou seja, quando houver realização muito alta da demanda pode ser preferível não atendê-la. Além disso, o tempo de execução do programa matemático aumentou de forma substancial com o aumento do número de cenários. Para o modelo SAA com 1 amostra de 200 cenários, o otimizador não atingiu o ótimo no limite de 3000 s.

Segue a tabela VI.5 que ilustra o tamanho do problema nas instâncias utilizadas:

Tabela VI.5 – Tamanho do modelo SAA sem roteamento

Número de cenários	nº de variáveis	nº de variáveis binárias	nº de restrições
50	10.046	4.000	15.006
100	20.046	8.000	30.006
150	30.046	12.000	45.006

Para a obtenção de limites inferiores foi usada a metodologia proposta por Shapiro e Homem-de-Mello (2001), que sugere o uso de um número a de amostras de tamanho n para a obtenção de um intervalo de confiança para a obtenção de um limite inferior com um nível α de significância.

As variáveis de custo da função objetivo estão representadas por meio de suas médias na tabela VI.6:

Tabela VI.6 – Resultados dos limites inferiores do modelo SAA sem roteamento

Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cost</i>	<i>ciet</i>	f.o. ($\alpha=5\%$)	tempo (s)
20	50	148.200	19.600	2.590.669	911.722	0	(3.647.303; 3.693.081)	115,37
	100	151.979	44.100	2.634.341	887.741	0	(3.705.682; 3.730.643)	517,77
	150	154.075	69.066	2.654.207	872.824	58	(3.736.910; 3.763.548)	3.983,26
100	50	149.216	22.540	2.595.813	909.083	0	(3.666.595; 3.686.711)	556,32
	100	153.964	44.450	2.651.296	883.703	0	(3.724.038; 3.742.789)	2.942,34
	150	154.572	64.633	2.658.527	876.755	0	(3.747.317; 3.761.655)	57.110,35

Percebe-se como o tempo de processamento aumentou exponencialmente com o aumento do número de cenários e que o desvio padrão do limite inferior da função objetivo é relativamente pequeno, cerca de um por cento.

Para a obtenção dos limites superiores foi usado o procedimento descrito na seção V.1.2, sendo que:

1. os valores das quantidades transportadas ($tr_{s,p,t,c}$) foram obtidos por Monte Carlo para um grupo de 150 cenários;
2. Em seguida, para amostras diferentes (foi usado a igual a 20 e a 100) de n cenários gerados por Monte Carlo (200 ou 500 cenários conforme ilustrado na tabela VI.7) foram calculados os valores das funções objetivo e das demais variáveis de decisão.

Tabela VI.7 – Resultados dos limites superiores do modelo SAA sem roteamento

Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i> ($\alpha=5\%$)	tempo (s)
20	200	154.078	277.725	2.651.566	875.821	1.181	(3.926.592 ; 3.994.151)	3.045,56
	500	154.214	249.900	2.654.991	874.649	2.310	(3.916.308 ; 3.955.820)	4.758,33
100	200	154.616	266.910	2.657.514	877.425	989	(3.945.060 ; 3.969.848)	17.637,24
	500	154.885	248.052	2.663.998	874.972	1.124	(3.933.592 ; 3.952.470)	20.856,68

Os *gaps* entre os valores médios dos limites inferiores e superiores foi de cerca de 5%, ou seja, conseguiu-se um intervalo estreito para o valor ótimo da função objetivo.

VI.3.3 – Resultados do Modelo sem Roteamento com Latin Hypercube Sampling (LHS)

Segue a tabela VI.8 os principais resultados, obtidos com as premissas da subseção V.1.3:

Tabela VI.8 – Resultados do modelo LHS sem roteamento (dividido em 5 espaços equiprováveis)

Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i> ($\alpha=5\%$)	tempo (s)
20	50	126.462	2.800	2.363.930	1.015.697	0	(3.498.880; 3.518.901)	101,16
	100	131.209	1.400	2.408.695	984.037	0	(3.517.132; 3.533.551)	456,81
	150	132.811	8.400	2.427.139	974.877	0	(3.536.543; 3.549.909)	1.341,27
100	50	128.024	1.680	2.374.434	1.008.776	0	(3.508.423; 3.517.406)	506,20
	100	131.239	7.350	2.410.234	985.112	0	(3.529.839; 3.538.033)	2.349,12
	150	132.376	11.200	2.420.522	976.661	0	(3.537.184; 3.544.332)	7.119,70

Conforme previsto, os valores dos limites inferiores foram cerca de 5% menores em relação aos resultados do SAA devido à média feita para utilização do teorema do limite central. Em suma, a utilização de médias reduziu a possibilidade de ocorrência de valores extremos, diminuindo assim o custo total esperado.

VI.3.4 – Resultados do Modelo sem Roteamento para Obtenção de Limites Superiores

Abaixo seguem os resultados para obtenção de limites superiores:

Tabela VI.9 – Resultados para obtenção de limites superiores para modelo sem roteamento

Nível de Probabilidade:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>
0,90	84.913	0	2.565.616	1.201.693	0	3.852.222
0,91	85.293	0	2.590.554	1.200.099	0	3.875.947
0,92	85.765	0	2.619.198	1.197.616	0	3.902.580
0,93	86.313	0	2.651.747	1.194.649	0	3.932.710
0,94	86.958	0	2.689.359	1.191.109	0	3.967.427
0,95	87.543	0	2.733.958	1.188.198	0	4.009.699
0,96	88.055	0	2.788.803	1.186.065	0	4.062.923
0,97	88.743	0	2.860.092	1.183.075	0	4.131.911
0,98	89.813	0	2.963.098	1.177.818	0	4.230.730
0,99	92.126	0	3.151.451	1.163.077	0	4.406.654
0,999	97.427	0	3.834.818	1.134.499	0	5.066.745

Por exemplo, a possibilidade de que as demandas das sondas sejam todas maiores que o nível de probabilidade 90 por cento é de 10^{-18} por cento. Em suma, usar um nível de probabilidade de 90 por cento parece oferecer um limite superior já bastante próximo aos limites inferiores obtidos pelo método SAA, ou seja, provavelmente os limites inferiores encontrados estão perto do ótimo.

VI.3.5 – Resultados do Modelo sem Roteamento com Redução de Cenários

Usando o algoritmo de redução de cenários, foi feita a exclusão de 300 cenários. Com o intuito de comparar resultados, foi implementada também a resolução do modelo com 400 cenários, tendo como limite de tempo 3.000 segundos.

Tabela VI.10 – Modelo sem roteamento e sem redução de cenários e com redução de cenários

	400 cenários	100 cenários (<i>com backward reduction</i>)
n ^o de variáveis	80.046	20.046
n ^o de variáveis binárias	32.000	8.000
n ^o de restrições	120.006	30.006
melhor solução	4.492.472	4.472.785
limite inferior	4.388.152	4.472.785
tempo de processamento (s)	3.000,00	222,81

Conclui-se que o algoritmo de redução de cenários obteve excelentes resultados já que a diferença entre as soluções foi pequena e o tempo de processamento do modelo com 100 cenários selecionados por com *backward induction* foi mais de dez vezes menor. Além disso, o *gap* em 3000 s para o modelo com 400 cenários ainda era de cerca de 100.000, ou seja, mais ou menos 2,5%.

VI.4. – Resultados dos Métodos de Resolução com Roteamento

Os modelos com roteamento apresentaram resultados da função objetivo bem menores, pois o custo de transporte total diminuiu muito (cerca de 80%). A inclusão de rotas com atendimento de múltiplas sondas faz que a distância total percorrida seja cerca de cinco a seis vezes menor. Com relação aos diversos métodos de resolução, observou-se, como decorrência, que a quantidade transportada de produtos por sonda por período era cerca de quinze por cento maior que no modelo sem roteamento.

O roteamento por ordem crescente de radianos obteve melhores resultados e é mostrado nas próximas subseções. As tabelas com o resultado do roteamento feito em ordem decrescente estão no apêndice.

Nos dois sentidos de roteamento, a última rota ficou com apenas uma sonda, mas no caso do roteamento em ordem crescente, essa sonda apresentava uma demanda maior, ou seja, não se prendia um rebocador com uma carga muito pequena.

Os tempos de processamento para todos os métodos de resolução também aumentaram muito com a inclusão de variáveis inteiras nas restrições e na função objetivo.

Os resultados das tabelas a seguir foram feitos com o número total de rebocadores afretados disponíveis sendo igual a seis. Esse pareceu um número razoável inicialmente, e os resultados das tabelas seguintes comprovaram essa ideia, visto que os custos de falta foram zero ou próximos de zero em todos os métodos de resolução.

VI.4.1 – Resultados dos Métodos de Resolução com Roteamento Discretizados

Nas tabelas VI.11 e VI.12 estão os resultados obtidos para o modelo discretizado com roteamento:

Tabela VI.11 – Resultados do modelo discretizado com roteamento em ordem crescente

Modelo:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>
RP	288.176	0	303.913	314.974	0	907.046
WS	279.716	0	303.863	253.960	0	837.540
EV	289.183	0	304.248	222.460	0	815.892
EEV	222.865	9.212.000	262.609	490.069	0	10.187.544

No modelo com roteamento, permaneceu relevante a inclusão da incerteza no modelo. De forma similar ao modelo sem roteamento, o valor do VSS foi muito alto e o do EVPI, baixo, conforme tabela VI.12:

Tabela VI.12 – EVPI e VSS para o modelo discretizado com roteamento em ordem crescente

EVPI	69.506
VSS	9.280.498

No modelo com roteamento o valor do VSS (cerca de nove milhões), apesar de substancial, foi bem menor que no modelo sem roteamento (cerca de 21 milhões). Tendo em vista a diminuição do custo de transporte no modelo com roteamento e consequente aumento das quantidades transportadas, esse resultado é coerente.

VI.4.2 – Resultados dos Métodos de Resolução com Roteamento e com SAA

Conforme esperado, os resultados foram bem melhores que os do modelo sem roteamento, cerca de 70% menores.

Tabela VI.13 – Resultados do modelo SAA com roteamento em ordem crescente com 1 amostra

Número de cenários:	Modelo:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>	tempo (s)	gap
50	RP	285.037	0	303.913	355.000	0	943.950	20,44	0%
	WS	278.030	0	304.080	258.060	0	840.171	1.000,00	0,56%
	EV	289.183	0	304.248	222.460	0	815.982	1,59	0%
	EEV	277.760	8.470.000	304.248	422.696	60.200	9.534.905	6,75	0%
100	RP	285.188	0	304.248	376.894	0	966.322	68,78	0%
	WS	278.512	0	304.063	255.690	0	830.564	1.000,00	0,92%
	EV	289.183	0	304.248	222.460	0	815.982	1,59	0%
	EEV	279.745	8.211.000	304.248	416.143	58.450	9.269.586	11,71	0%
150	RP	287.403	0	303.913	362.313	0	953.629	194,66	0%
	WS	279.286	0	304.135	253.520	0	836.941	1.000,00	1,37%
	EV	289.183	0	304.248	222.460	0	815.982	2,87	0%
	EEV	280.649	8.110.667	304.248	414.713	63.233	9.173.510	9,23	0%

Interessante notar que o otimizador demorou muito tempo para resolver o problema WS. Tendo como tempo limite cerca de 1000 segundos, em nenhuma das instâncias foi atingida a solução ótima. A inclusão de restrições adicionais poderiam provavelmente poderiam melhorar o tempo de resolução do problema.

A tabela VI.14 mostra como varia o tamanho do problema com o aumento do número de cenários:

Tabela VI.14 – Tamanho do modelo SAA com roteamento

número de cenários	nº de variáveis	nº de variáveis binárias e inteiras	nº de restrições
50	10.052	4.006	15.014
100	20.052	8.006	30.014
150	30.052	12.006	45.014

Em suma, o número de variáveis (reais e inteiras) e restrições aumenta linearmente com o número de cenários mas o tempo de resolução aumenta exponencialmente com o número de cenários conforme pode ser visto nas tabelas VI.13 e VI.15. Pela tabela VI.13, o tempo de resolução do problema aumenta mais de dez vezes quando o número de cenários é triplicado (de 50 para 150). Pela tabela VI.15 com vinte amostras, o aumento de processamento aumenta ainda mais (cerca de cinquenta vezes) com o mesmo aumento do número de cenários (de 50 para 150). Com cem amostras, esse número é ainda maior.

Tabela VI.15 – Resultados dos limites inferiores do modelo SAA com roteamento em ordem crescente

Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i> ($\alpha=5\%$)	tempo (s)
20	50	287.132	0	304.014	360.498	0	(945.671; 957.617)	320,55
	100	286.946	1400	304.014	369.610	0	(955.911; 968.026)	1.369,23
	150	286.805	3.733	303.965	374.003	117	(961.404; 975.840)	3.863,53
100	50	286.873	56	304.010	360.249	35	(949.199; 954.254)	1.552,92
	100	286.634	4.760	303.984	373.644	322	(966.015; 972.264)	9.901,90
	150	286.758	4340	304.104	375.874	268	(968.489; 974.196)	24.296,83

Para a obtenção dos limites superiores foi usado novamente o procedimento descrito na seção V.1.2, sendo que:

1. os valores das quantidades transportadas ($tr_{s,p,t,c}$) foram obtidos por Monte Carlo para um grupo de 150 cenários;
2. Em seguida, para a amostras diferentes (foi usado a igual a 20 e a 100) de n cenários gerados por Monte Carlo (200 ou 500 cenários conforme ilustrado na tabela VI.16) foram calculados os valores das funções objetivo e das demais variáveis de decisão.

Tabela VI.16 – Resultados dos limites superiores do modelo SAA com roteamento em ordem crescente

Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i> ($\alpha=5\%$)	tempo (s)
20	200	287.010	58.275	304.098	374.404	0	(1.010.773 ; 1.036.801)	4.105,40
	500	287.053	63.140	304.098	376.582	0	(1.020.765; 1.040.799)	4.803,67
100	200	286.968	72.170	304.058	375.762	0	(1.030.995 ; 1.046.922)	19.970,65
	500	286.879	73.346	304.104	375.764	0	(1.033.398 ; 1.046.789)	24.832,40

A tabela VI.15 mostra que o intervalo de confiança do limite inferior é bastante estreito para $\alpha=5\%$, cerca de 10 mil no modelo com vinte amostras e cerca de 5 mil no modelo com cem amostras. Nos dois casos, menos de 1% do valor do limite superior do intervalo de confiança do limite inferior.

As parcelas de custo da função objetivo não variaram muito com o número de amostras e de cenários, com exceção do *cft* e do *ciet* que, apesar de continuarem pequenos como percentual do total de custos esperados, aumentaram bastante em relação aos valores de instâncias com menores números de amostras e de cenários. A razão disso é que, com o aumento o número de cenários e a consequente diminuição da probabilidade de cada cenário, vale a pena assumir custos de falta e de retorno das embarcações de apoio maiores.

A tabela VI.16 mostra que os valores médios dos limites superiores obtidos foram próximos dos valores médios dos limites inferiores, o *gap* foi de cerca de 7%, ou seja, o método gerou resultados satisfatórios. Além disso, o desvio-padrão dos intervalo de confiança dos limites superiores foi de cerca de 20.000, ou seja, de cerca de 2%.

VI.4.3 – Resultados dos Métodos de Resolução com Roteamento e com LHS

Os resultados da função objetivo do modelo com roteamento e com LHS, mais uma vez obtidos com as premissas da subseção V.1.3, variaram pouco com o aumento do número de cenários e de amostras.

Tabela VI.17 – Resultados do modelo LHS com roteamento em ordem crescente

Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o. (α=5%)</i>	tempo (s)
20	50	285.697	0	303.913	327.608	0	(915.731; 918.705)	301,86
	100	286.977	0	303.913	327.678	0	(916.638; 920.498)	1.323,04
	150	286.934	0	303.913	328.212	0	(917.474; 920.643)	3807,22
100	50	286.074	0	303.913	327.021	0	(916.179; 917.842)	1.480,94
	100	286.417	0	303.913	328.275	0	(917.678; 919.240)	12.404,80
	150	286.600	0	303.913	328.207	0	(918.201; 919.236)	21.229,44

Tal como no modelo sem roteamento, os limites inferiores encontrados usando a amostragem por LHS foram menores do que aqueles usando SAA por se usarem valores médios no processo conforme explicado no capítulo V. Nesse aspecto, tanto os modelos com e sem roteamento obtiveram resultados similares, já que nos dois o custo do método LHS foi menor.

O intervalo de confiança dos limites inferiores foi bem estreito, cerca de 2 mil.

Com o uso de valores mais próximos das médias, o custo de falta foi de zero em todas as instâncias. Houve também pouca variação nas demais parcelas dos custos totais em todas as instâncias.

VI.4.4 – Resultados do Modelo com Roteamento para Obtenção de Limites Superiores

Nessa forma de resolução como o número total de rebocadores é adequado, apenas numa hipótese de demanda 0,9999 da função demanda de probabilidade acumulada de todas as sondas para produtos químicos haveria custo de falta. Em suma, com esse tamanho de frota os custos de falta podem ser evitados com quase cem por cento de certeza, conforme mostra a tabela VI.18:

Tabela VI.18 – Resultados para obtenção de limites superiores para modelo com roteamento em ordem crescente

Nível de Probabilidade:	<i>cit</i>	<i>cft</i>	<i>cttr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>
0,90	225.370	0	303.913	420.186	0	949.469
0,91	219.402	0	301.257	433.709	0	954.368
0,95	211.188	0	301.257	465.901	0	978.346
0,99	177.422	0	301.257	590.550	0	1.069.230
0,999	123.565	0	301.592	864.564	0	1.289.721
0,9999	88.453	2.800.000	301.257	1.046.191	0	4.235.902

Um aspecto interessante nessa forma de resolução é que mesmo para valores razoavelmente bem altos dos níveis de probabilidade, como 0,90, o valor da função objetivo é menor que o limite inferior obtido pelo SAA com roteamento para 100 amostras de 150 cenários cada. Em suma, são necessários níveis de probabilidade bastantes altos para que de fato os valores da função objetivo sejam válidos como limites superiores. Essa dificuldade decorre do fato de que nessa forma de resolução são usados apenas valores altos de demanda, ao contrário do que ocorre no SAA no qual valores altos baixos tendem a ocorrer com a mesma frequência. Como resultado dessa maior variabilidade da demanda, há um maior custo de estoque esperado e de custo abaixo do estoque de segurança esperado na resolução por SAA.

Mais uma vez os custos de transporte pouco se alteram ou não se alteram com o aumento dos níveis de probabilidade. Os custos de se estar abaixo do estoque de segurança (*cst*) é que vão aumentando com o acréscimo nos níveis e probabilidade. Isso é esperado pois como o número de rebocadores total é fixo, quando a demanda atinge altas probabilidades todos os rebocadores estão usando toda sua capacidade e não se pode transportar mais carga, de modo que os estoques passam a ficar abaixo do estoque de segurança, ou seja, diminui-se o *cit* e aumenta-se o *cst*.

VI.4.5 – Resultados do Modelo com Roteamento e com Redução de Cenários

O método funcionou bem já que o tempo de processamento foi bem mais baixo (mais de dez vezes menor que o modelo com 400 cenários) e o valor ótimo obtido está dentro do intervalo entre a melhor solução e o limite inferior obtidos no modelo sem redução de cenários com tempo máximo de resolução de 12.000 segundos (em 3.000 segundos ainda não tinha sido encontrada uma solução viável), conforme tabela VI.19:

Tabela VI.19 – Modelo com roteamento em ordem crescente sem redução de cenários e com redução de cenários

	400 cenários	100 cenários (<i>com backward reduction</i>)
nº de variáveis	80.052	20.052
nº de variáveis binárias ou inteiras	32.006	8.006
nº de restrições	120.014	30.014
melhor solução	1.103.433	1.094.006
limite inferior	1.060.913	1.094.006
tempo de processamento (s)	12.000	623.81

Outro resultado interessante é que os cenários iniciais geram casos extremos que acabam sendo mais custosos que os valores obtidos no método SAA, visto que a variabilidade da demanda na construção dos 400 cenários usados nesse método é maior que a da demanda do método SAA. Enquanto no SAA os valores da função de distribuição de probabilidade de produtos químicos são maiores perto da média, na construção desses 400 cenários, valores que estejam nos extremos têm a mesma probabilidade de ocorrerem. Essa maior variabilidade da demanda faz que os custos totais esperados de estoques e de estoque de segurança sejam maiores.

VI.5 – Síntese dos Principais Resultados

Nos métodos de resolução com roteamento, houve grande redução de custos em relação aos modelos sem roteamento devido à redução da distância total percorrida. De modo geral, os resultados da solução ótima e dos respectivos componentes de custos pouco variaram com o aumento do número de cenários, ou seja, foram robustos.

Nos modelos com roteamento, a obtenção de limites superiores foi mais complexa. Só com valores muito altos de probabilidade, foram obtidos limites válidos.

Destaque-se que o aumento do número de cenários aumentou exponencialmente o tempo de processamento do modelo.

O pequeno *gap* entre os limites inferiores e superiores no método SAA tanto no modelo sem roteamento quanto no modelo com roteamento sugere que o uso do SAA gerou resultados adequados.

VII – CONCLUSÕES

Conforme verificado nos resultados do capítulo VI, é possível concluir que o modelo estocástico formulado pode fornecer economias consideráveis em relação a um modelo determinístico no qual se usa o valor médio das variáveis estocásticas. Aqui como em outros setores de cadeia de suprimentos os êxitos têm sido consideráveis.

O aspecto inovador dessa tese consistiu em considerar os custos logísticos *offshore* com incerteza e todas suas particularidades (em particular o alto custo de falta causado pela falta de qualquer unidade de produto), numa perspectiva de cadeia de suprimentos, na qual foram considerados não só custos de transporte mas também os custos de falta, custos de estoque e os custos de estoques de segurança. No melhor do nosso conhecimento, não foram encontrados trabalhos similares na literatura acadêmica.

Destaque-se que, dadas a grande quantidade de operações *offshore* executadas pela PETROBRAS, mesmo pequenas economias em termos percentuais podem significar ganhos expressivos. Além disso, as operações *offshore* necessitam de um alto nível de serviço mas que não são necessariamente níveis de 100% como frequentemente é questionado na empresa. Como os exemplos numéricos desse trabalho mostram, pode não valer a pena ter custo de falta esperado zero.

Trabalhos futuros podem ser realizados tanto nos aspectos da abordagem matemática quanto na incorporação de mais aspectos da realidade ao problema modelado. No primeiro conjunto pode-se destacar:

Acrescentar coeficientes de aversão ao risco na função objetivo tende a deixar o problema mais próximo da prática, pois na realidade o tomador de decisão tende a ser avesso ao risco e, não, neutro ao risco com em um modelo que inclui

apenas o valor esperado na função objetivo. Destarte, modelos com *CvaR* e *downside risk* constituem boas opções.

A inclusão de restrições de probabilidade no modelo deve ser considerada dada a peculiaridade do problema de que os custos dos piores cenários podem não ser aceitáveis.

A seleção do roteamento por meio de outras heurísticas e metaheurísticas ou resolução por métodos de programação inteira-mista também pode gerar resultados melhores principalmente ao se tratar de um problema maior, mais parecido com o caso real, em que há mais de 30 sondas para se fazer o planejamento do roteamento e das cargas a serem transportadas.

Do ponto de vista da inclusão de aspectos mais realistas ao problema podem ser sugeridos:

Acrescentar o tempo de cada operação como outra variável estocástica do modelo. O atraso da sonda em outras operações pode afetar sobremaneira o Valor Presente Líquido (VPL) do projeto. Ressalte-se entretanto que a dificuldade em medir o VPL reside no fato de que o atraso na produção pode ser causado por atrasos em diversas atividades, além das operações de sonda, como:

- na instalação das árvores de natal, dos dutos submarinos e dos *manifolds*, quando fizerem parte do projeto;
- na ancoragem das unidades de produção;
- na ligação dos *risers* com as unidades de produção.

Aumentar o número de sondas no modelo e incluir o conjunto de todos os produtos, divididos em grandes categorias (produtos como rancho, água e diesel devem ser tratados como variáveis determinísticas pois sua demanda é praticamente constante), ou seja, passaria a ser feito o planejamento para todas as cargas a serem transportadas nos barcos supridores.

O objeto de estudo desse trabalho foi o planejamento de curto prazo, mas resultados interessantes podem ser obtidos se o modelo for ampliado e usado para um planejamento de médio e de longo prazos no qual o dimensionamento da quantidade ótima de barcos supridores seria uma das variáveis de decisão.

Outra possibilidade é checar se o modelo trará bons resultados para outras áreas, como a Bacia de Santos, ressaltando que, como essa é uma área de exploração mais recente que a Bacia de Campos, as incertezas tendem a ser maiores, ou seja, torna-se mais importante incluir as incertezas nos modelos de planejamento.

REFERÊNCIAS BIBLIOGRÁFICAS

AHMED S., SAHINIDIS N.V. Robust process planning under uncertainty. *Ind Eng Chem Res.* (1998), 37: pp. 1883–1892.

BARBARO, A.F., BAGAJEWICZ, M. Managing financial risk in planning under uncertainty. *AIChE J.* (2004), 50: pp. 963–989.

BEALE, E.M.L. On minimizing a convex function subject to linear inequalities. *J. Royal Statistical Society* (1955), Series B 17, pp. 173-184.

BIEGLER, L. T., GROSSMANN, I E. Retrospective on Optimization. *Comp. and Chem. Eng.*, 28 (2004), pp-1169-1192.

BIRGE, J.R., LOUVEAUX F. *Introduction to Stochastic Programming.* New York: Springer-Verlag (2012). Second Edition.

BISSCHOP, J. AIMMS Optimization Modeling, Paragon Decision Technology_online (2012)

BLAZEWICZ, J., DROR M., WEGLAR J., *Mathematical Programming Formulations for Machine Scheduling: A Survey*, *European Journal of Operations Research* 51 (1991), pp. 283-300.

BLAZEWICZ, J., LENSTRA, J. K.; RINNOOY KAN, A. H. G. Scheduling Projects to Resource Constraints: Classification and Complexity. *Discrete Applied Mathematics* 5 (1983), pp.11-24.

CAENN R., CHILLINGAR V. G. Drilling Fluids: State of the Art. *Journal of Petroleum Science and Engineering* 14 (1996), pp. 221-230.

CASELLA, G., BERGER, R. G. *Statistical Inference.* Duxbury Advanced Series (2002) Second Edition.

CRUZ, C. A. O. Scheduling de Projeto de Equipamentos para Produção de Petróleo sob Condições de Incerteza. Tese de Doutorado COPPE-UFRJ (2013).

DANTZIG, G.B., "Linear Programming under uncertainty". *Management Science* 1 (1955) pp. 197-206.

DUPACOVA, J., GROWE-KUSKA, N., ROMISCH, W. Scenario Reduction in Stochastic Programming. An Approach Using Probability Metrics. *Math. Program., Ser. A* 95: 493-511 (2003).

GEBRESLASSIE, H. B., YAO, Y., YOU, F. Design under Uncertainty of Hydrocarbon Biorefinery Supply Chains: Multiobjective Stochastic Programming Models, Decomposition Algorithm, and a Comparison Between CVar and Downside Risk. *American Institute of Chemical Engineers AIChE J* (2012), 58: pp. 2155-2179.

GILLETT, B., MILLER, L. A Heuristic Algorithm for the Vehicle Dispatch Problem. *Operations Research* 22 (1974), pp. 340-349.

GROSSMANN, I. E. Enterprise-wide Optimization: A New Frontier in Process Systems Engineering. Published online June 14, (2005) in Wiley InterScience (www.interscience.wiley.com).

GROSSMANN, I. E. Advances in Mathematical Programming Models for Enterprise-wide Optimization. *Computers and Chemical Engineering* (2012), <http://dx.doi.org/10.1016/j.compchemeng.2012.06.038>.

GROSSMANN, I. E. Review of Nonlinear Mixed-Integer and Disjunctive Programming Techniques. *Optimization and Engineering*, 3 (2002), pp. 227-252.

GUPTA, V., GROSSMANN, I. E. Solution Strategies for Multistage Stochastic Programming with Endogenous Uncertainties. *Computers and Chemical Engineering* 35 (2011), pp. 2235-2247.

HASHEM, S. M. J. M A., ARYANEZHAD, M. B., SADJADI, S. J. An Efficient Algorithm to Solve a Multi-Objective Robust Aggregate Planning in an Uncertain Environment. *International Journal of Advanced Manufacturing Technology*, 58 (2012), pp. 765-782.

HEITSCH, H., ROMISCH, W. Scenario Reduction Algorithms in Stochastic Programming. *Computational Optimization and Applications*, 24, (2003); pp.187-206.

HOLLMANN, D. Supply Chain Network Design under Uncertainty and Risk. Tese de Doutorado Brunel University (2011).

HOMEM-DE-MELLO, T., BAYRAKSAN G. Monte Carlo Sampling-Based Methods for Stochastic Optimization. [online] http://www.optimization-online.org/DB_HTML/2013/06/3920.html (2013).

KAISER, M. J. A Survey of Drilling Cost and Complexity Estimation Models. International Journal of Petroleum Science and Technology Volume 1, Number 1. pp. 1-22 (2007).

KAISER, M. J. Modeling the time and cost to drill an offshore well. Energy (Oxford) Y., vol. 34, No. 9, pp. 1097-1112 (2009).

KAISER, M. J, PULSIPHER, A. G. Generalized Functional Models for Drilling Cost Estimation. SPE Drilling & Completion Volume 22, Number 2, pp. 67-73, June (2007).

KALL, P, WALLACE, S.W. Stochastic Programming. Jonh Wiley & Sons, (1994).

KARUPPIAH, R, MARTÍN, M., GROSSMANN, I. E. A Simple Heuristic for Reducing the Number of Scenarios in Two-Stage Stochastic Programming. Computers and Chemical Engineering, 34, (2010), pp. 1246–1255.

KEEFER, D. L. Certainty Equivalent for Three-Point Discrete-Distribution Approximations. Management Science, v.40, n.6 (1994), pp. 760-773.

KHOR, C. S., SHAH, N. Optimal Process Planning Uncertainty with Risk Management. FOCAPO POSTER SESSION A (2012), paper 38.

KLEYWEGT, J. A., SHAPIRO, A., HOMEM-DE-MELLO, T. The Sample Average Approximation Method for Stochastic Discrete Optimization. Society for Industrial and Applied Mathematics Vol. 12, No. 2 (2001), pp. 479–502.

LAPORTE, G. The Vehicle Routing Problem: An overview of exact and approximate algorithms. European Journal of Operational Research 59 (1992), pp. 345-358.

LEITE, R. P. Maritime transport of deck cargo to Petrobras fields in Campos Basin: an empirical analysis, identification and quantification of improvement points. Dissertação de Mestrado defendida na PUC/RJ (2012).

LI, Z., DING, R., FLOUDAS, C. A. A Comparative Theoretical and Computational Study on Robust Counterpart Optimization: I. Robust Linear Optimization and Robust Mixed

Integer Linear Optimization. *Industrial and Engineering Chemistry Research*, 50 (2011), pp. 10567–10603.

LINDEROTH, J., SHAPIRO, A., WRIGHT S. The Empirical Behaviour of Sampling Methods for Stochastic Programming. *Annals of Operations Research* 142, (2006), pp-215-241.

MAK W-K., MORTON D.P., WOOD R.K. Monte Carlo Bounding Techniques for Determining Solution Quality in Stochastic Programs. *Oper Res Lett.* (1999); 24: pp. 47–56.

MAS-COLLEL A., WHINSTON M. D., GREEN J. R. *Microeconomic Theory*. Oxford University Press (1995).

MAZZINI F. F., ACCIOLY R. M. S., VASCONCELOS R. V. J. C. Dimensionamento de Equipamentos Críticos da Cadeia de suprimento da Perfuração e Completação de Poços. XLII SOBRAPO (2010).

McKAY, M. D., BECKMAN, R. J., CONOVER, W. J. A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code. *Technometrics*, 21: pp. 239-245 (1979).

MITCHELL B. A Comparison of Chi-Square and Kolmogorov-Smirnov Tests. *Royal Geographic Society* (1971), Vol3. No4, pp. 237-241.

MORAES, L. Uso de Modelos de Otimização pela Área de Gás & Energia da PETROBRAS. XLV SOBRAPO (2013).

OLIVEIRA, F. *Petroleum Supply Chain Management under Uncertainty: Models and Algorithms*. Tese de Doutorado defendida na PUC/RJ (2012).

PERDIGÃO. <<http://www.unisoma.com.br/br/casos-agroindustrias-4.php>>

POOJARI, C.A, LUCAS C., MITRA G. Robust Solutions and Risk Measures for a Supply Chain Planning Problem under Uncertainty. *Journal of the Operational Research Society* (2008), 59, pp. 2-12.

ROCHA, L. A. S., AZEVEDO C. T. *Projetos de Poços de Petróleo*. Editora Interciência (2009) Segunda Edição.

RUSZCZYNSKI, A., SHAPIRO, A. Stochastic Programming (HANDBOOK IN OPERATIONS RESEARCH AND MANAGEMENT SCIENCE VOLUME 10). Elsevier Science, 2003.

SAHINIDIS, N. V. Optimization under Uncertainty: State-of-the-Art and Opportunities. Computers & Chemical Engineering (2004), 28, pp. 971-983.

SCHUTZ, P. Managing Uncertainty and Flexibility in Supply Chain Optimization. Doctoral Thesis at NTNU (2009).

SCHUTZ, P., TOMASGARD, A., AHMED, S. Supply Chain Design Under Uncertainty Using Sample Average Approximation and Dual Decomposition. European Journal of Operational Research 199 (2009), pp. 409-419.

SHAPIRO, A. Stochastic Programming by Monte Carlo Simulation Methods. Stochastic Program E-Prints Series. 03 (2000).

SHAPIRO, A. On Complexity of Multistage Stochastic Programs. Operations Research Letters 34 (2006), pp. 1–8.

SHAPIRO A., HOME-DE-MELLO, T. A simulation-based approach to two-stage stochastic programming with recourse. Math Program. (2001); 81: pp. 301–325.

SHAPIRO, A., DENTCHEVA, D., RUSZCZYNSKI A. Lectures on Stochastic Programming Modeling and Theory. MPS-SIAM series on optimization; 9 (2009).

SHYSHOU A., GRIBKOVSKAIA I., BARCELÓ J. A Simulation Study of the Fleet Sizing Problem arising in Offshore Anchor Handling Operations. European Journal of Operational Research 203 (2010), pp. 230-240.

STOCHASTIC PROGRAMMING WIKIPEDIA, 2012, [online]. <http://en.wikipedia.org/wiki/Stochastic_programming>.

SUBRAHMANYAM S, PEKNEY J. F., REKLAITIS G.V. Design of Batch Chemical Plants under Market Uncertainty. Ind Eng Chem Res.,33: pp. 2688–2701, (1994).

TAVARES, L.V, FERREIRA J.A. A., COELHO J.S. On the Optimal Management of Project Risk. European Journal of Operations Research 107 (1998), pp. 451-469.

TAVARES, L.V. A Review of the Contribution of Operational Research to Project Management. European Journal of operational Research 136 (2002), pp. 1-18.

THOMAS, J.E (organizador). Fundamentos de Engenharia de Petróleo. Editora Interciência (2004).

UGLANE, V. T., FRIEDBERG, D. O. Routing and Scheduling of Platform Supply Vessels in the Brazilian Oil Industry. Project Thesis (2012) NTNU.

VASCONCELOS, R. V. J. C. Um Algoritmo Genético para o Problema de Scheduling de Projetos com Restrição de Recurso - uma Solução com Gerenciamento de Risco. Tese de Doutorado COPPE-UFRJ (2007).

WESTNEY R. E. Managing the Cost & Schedule Risk of Offshore Development Projects. OTC 12979 (2001).

YOU, F., WASSICK, J. M., GROSSMANN, I. E. Risk Management for a Global Supply Chain Under Uncertainty: Models and Algorithms. AIChE J v55, n.4, (2009), pp.931-946.

ANEXO I

Resultados dos Testes de Aderência Relativos a Produtos Químicos por Sonda

S1

Distribution	rank	Acceptance
Weibull(-21.4, 6.99, 37.5)	98	do not reject
Johnson SB(-121, 161, -6.09, 3.67)	97.7	do not reject
Beta(1.13, 22.8, 1.68, 1.21)	94.5	do not reject
Logistic(13.9, 3.48)	80	do not reject
LogLogistic(-85.3, 28.1, 99.2)	74.1	do not reject
Extreme Value IB(16.6, 5.08)	73.3	do not reject
Normal(13.7, 5.99)	63.6	do not reject
Lognormal(-1.2e+003, 7.1, 4.95e-003)	62.5	do not reject
Power Function(0.927, 22.9, 1.25)	44.3	do not reject
Pearson 5(-46.8, 90.9, 5.44e+003)	36.1	do not reject
Triangular(-2.49, 22.8, 22.8)	22	do not reject
Rayleigh(-7.44e-002, 10.6)	8.14	do not reject
Uniform(1.13, 22.8)	2.95	do not reject

S2

Distribution	rank	acceptance
LogLogistic(3.56, 2.57, 31.3)	97.2	do not reject
Gamma(7.15, 1.93, 17.9)	86.8	do not reject
Inverse Gaussian(-3.37, 143, 45.)	83.3	do not reject
Lognormal(-1.41, 3.61, 0.559)	79.5	do not reject
Pearson 5(-11.8, 5.79, 258)	78.2	do not reject
Weibull(8.43, 1.39, 36.4)	77.6	do not reject
Erlang(7.15, 2., 17.3)	74.8	do not reject
Inverse Weibull(-62.9, 5.74, 1.08e-002)	72.2	do not reject
Pearson 6(9.41, 101, 2.49, 8.4)	46.9	do not reject
Extreme Value IA(31.4, 18.7)	21.8	do not reject
Beta(9.41, 101, 1.45, 2.79)	18.5	do not reject

Power Function(9.34, 111, 0.625)	13.9	do not reject
Exponential(9.41, 32.3)	13.3	do not reject
Logistic(39.2, 13.7)	11.8	do not reject
Chi Squared(-247, 289)	7.84	Reject
Rayleigh(1.95, 32.7)	6.04	Reject
Normal(41.7, 23.6)	5.26	Reject
Triangular(4.08, 108, 24.2)	4.65	Reject
Extreme Value IB(54.2, 25.9)	4.15	Reject
Pareto(9.41, 0.755)	4.49E-03	Reject
Uniform(9.41, 101)	4.12E-03	Reject
Johnson SB(10.8, 74.8, 0.359, 0.669)	0	Reject

S3

Distribution	rank	acceptance
Normal(29., 8.04)	96.8	do not reject
Logistic(29.1, 4.44)	96.5	do not reject
Lognormal(-738, 6.64, 1.05e-002)	96	do not reject
Weibull(2.69, 3.58, 29.1)	95.1	do not reject
Pearson 5(-51.8, 92.5, 7.4e+003)	78.5	do not reject
Beta(11., 49.5, 3.67, 4.31)	70.5	do not reject
Triangular(8.14, 51.7, 28.6)	56.8	do not reject
Extreme Value IB(33.1, 8.25)	47.9	do not reject
Rayleigh(9.65, 14.8)	12.4	do not reject
Uniform(11., 49.5)	0.374	do not reject
Power Function(10.7, 54.1, 0.925)	0.108	Reject
LogLogistic	no fit	Reject
Johnson SB	no fit	Reject

S4

Distribution	rank	acceptance
Extreme Value IB(14.3, 4.86)	100	do not reject
Triangular(-3.38, 22.9, 15.9)	98.3	do not reject

Weibull(-66.4, 16.2, 80.5)	97.6	do not reject
Johnson SB(-1.88, 24.8, -0.14, 0.833)	70	do not reject
LogLogistic(-2.8e+005, 8.2e+004, 2.8e+005)	67.1	do not reject
Logistic(11.9, 3.38)	63.2	do not reject
Beta(-9.45, 21.8, 4.51, 2.38)	55.7	do not reject
Normal(11.5, 5.8)	49.2	do not reject
Lognormal(-1.2e+003, 7.1, 4.79e-003)	48.2	do not reject
Power Function(0.201, 22.2, 0.985)	32.8	do not reject
Pearson 5(-53.8, 116, 7.49e+003)	30.5	do not reject
Uniform(0.417, 21.8)	15.8	do not reject
Rayleigh(-1.29, 9.94)	11.1	do not reject

S5

Distribution	rank	acceptance
LogLogistic(5.49, 2.71, 11.8)	100	do not reject
Inverse Weibull(-8.81, 4.08, 4.2e-002)	90.3	do not reject
Pearson 5(1.85, 4.45, 63.1)	85.3	do not reject
Lognormal(5.66, 2.44, 0.686)	75.6	do not reject
Inverse Gaussian(5.04, 29., 15.2)	71.2	do not reject
Extreme Value IA(15.9, 6.75)	63.4	do not reject
Pearson 6(8.48, 44.6, 1.63, 6.95)	61	do not reject
Beta(8.48, 1.16e+007, 1.34, 1.27e+006)	44	do not reject
Logistic(18.2, 5.06)	38.6	do not reject
Exponential(8.48, 11.7)	22	do not reject
Erlang(8.48, 1., 11.7)	22	do not reject
Gamma(8.48, 1., 11.7)	22	do not reject
Chi Squared(-18.1, 38.)	14.5	do not reject
Weibull(8.48, 0.942, 11.5)	12.2	do not reject
Rayleigh(2.92, 14.9)	1.27	do not reject
Normal(20.2, 12.)	0.642	Reject
Pareto(8.48, 1.33)	0.238	do not reject
Extreme Value IB(27.5, 18.7)	1.13E-02	Reject

Power Function(8.48, 167, 0.302)	1.50E-04	Reject
Triangular(8.45, 72., 8.48)	0	Reject
Uniform(8.48, 69.3)	0	Reject
Johnson SB	no fit	Reject

S6

Distribution	rank	acceptance
Pearson 6(10.1, 70.7, 6.72, 23.5)	100	do not reject
Pearson 5(-45.4, 61.9, 4.61e+003)	98.9	do not reject
LogLogistic(-172, 37.2, 202)	97	do not reject
Chi Squared(-18.1, 48.5)	95.8	do not reject
Lognormal(-59.6, 4.49, 0.107)	94.2	do not reject
Erlang(-34.7, 45., 1.45)	93.2	do not reject
Gamma(-34.7, 45.1, 1.44)	92.8	do not reject
Logistic(30., 5.45)	91.8	do not reject
Triangular(7.6, 54.9, 28.2)	90.9	do not reject
Beta(10.1, 108, 4.25, 15.6)	86.9	do not reject
Weibull(4.79, 2.85, 28.7)	86.6	do not reject
Extreme Value IA(25.6, 8.81)	84.4	do not reject
Inverse Gaussian(-59.8, 7.85e+003, 90.1)	78.9	do not reject
Normal(30.4, 9.65)	76.7	do not reject
Rayleigh(8.62, 16.8)	52	do not reject
Extreme Value IB(35.3, 9.85)	16.2	do not reject
Uniform(10.1, 50.3)	9.19	do not reject
Power Function(10.1, 50.4, 1.35)	1.43	do not reject
Exponential(10.1, 20.3)	1.29E-02	Reject
Pareto(10.1, 0.957)	3.16E-05	Reject
Inverse Weibull	no fit	Reject
Johnson SB	no fit	Reject

S7

Distribution	rank	acceptance
--------------	------	------------

Inverse Weibull(12.7, 1.34, 7.4e-002)	100	do not reject
Pearson 5(13.4, 1.51, 20.6)	96	do not reject
Pearson 6(17.2, 5.08, 3.3, 1.39)	94.9	do not reject
Inverse Gaussian(15., 16.9, 30.)	92.2	do not reject
Lognormal(16.3, 2.72, 1.17)	91.1	do not reject
LogLogistic(17.2, 1.51, 14.7)	83.1	do not reject
Weibull(17.2, 0.812, 24.7)	34.7	do not reject
Pareto(17.2, 1.32)	22.6	do not reject
Gamma(17.2, 0.982, 28.3)	10.2	do not reject
Exponential(17.2, 27.8)	9.28	do not reject
Erlang(17.2, 1., 28.3)	7.86	do not reject
Beta(17.2, 126, 0.623, 1.63)	1.19	do not reject
Power Function(17.1, 126, 0.458)	0.867	do not reject
Extreme Value IA(32.1, 21.2)	0.487	Reject
Logistic(37.3, 16.8)	0.428	reject
Chi Squared(-530, 576)	4.93E-02	reject
Normal(45., 33.3)	3.22E-02	reject
Extreme Value IB(63.6, 39.8)	9.94E-03	reject
Rayleigh(-3.41, 41.5)	8.93E-03	reject
Triangular(17.2, 137, 17.2)	1.87E-05	reject
Uniform(17.2, 126)	0	reject
Johnson SB	no fit	reject

S8

Distribution	rank	acceptance
Lognormal(7.63, 2.3, 1.29)	94.1	do not reject
Pearson 5(4.87, 1.46, 14.7)	81.7	do not reject
Power Function(8.22, 52.9, 0.584)	69.8	do not reject
Inverse Gaussian(6.2, 12.5, 19.9)	67.7	do not reject
Pearson 6(8.4, 4.1e+003, 1.13, 236)	65.3	do not reject
Weibull(8.4, 0.852, 16.5)	62	do not reject
Exponential(8.4, 17.7)	57.5	do not reject

Logistic(25., 10.1)	54.4	do not reject
LogLogistic(-299, 32.7, 324)	52.4	do not reject
Extreme Value IA(18.7, 12.9)	51.4	do not reject
Beta(8.4, 51., 0.745, 1.11)	50.5	do not reject
Extreme Value IB(34.3, 14.9)	50.2	do not reject
Chi Squared(-99., 125)	49.9	do not reject
Normal(26.1, 16.)	49.4	do not reject
Pareto(8.4, 1.08)	48.7	do not reject
Gamma(-72.5, 39.9, 2.47)	47	do not reject
Erlang(-72.5, 40., 2.47)	46.6	do not reject
Rayleigh(-0.616, 22.)	38.4	do not reject
Triangular(8.36, 66.7, 8.36)	16.9	do not reject
Uniform(8.4, 51.)	9.92	do not reject
Johnson SB(8.78, 41.2, 0.364, 0.528)	1.50E-14	reject
Inverse Weibull	no fit	reject

S9

Distribution	rank	acceptance
Inverse Weibull(-5.25, 1.63, 4.96e-002)	100	do not reject
Pearson 5(-2.51, 1.79, 33.2)	97.3	do not reject
Pearson 6(3.7, 6.42, 4.4, 1.79)	90	do not reject
Lognormal(1.72, 2.93, 1.08)	85.4	do not reject
Inverse Gaussian(-0.112, 25.2, 33.8)	79.4	do not reject
LogLogistic(3.7, 1.71, 18.7)	78	do not reject
Exponential(3.7, 29.9)	26.4	do not reject
Erlang(3.7, 1., 29.9)	26.4	do not reject
Gamma(3.7, 1., 29.9)	26.4	do not reject
Weibull(3.7, 0.81, 26.9)	24.8	do not reject
Extreme Value IA(20.6, 22.4)	2.12	reject
Logistic(26.4, 17.2)	0.925	reject
Power Function(3.63, 102, 0.489)	0.622	do not reject
Chi Squared(-554, 588)	0.133	reject

Normal(33.6, 33.6)	8.85E-02	reject
Rayleigh(-15.9, 42.3)	5.72E-02	reject
Beta(3.7, 102, 0.521, 0.769)	3.79E-02	reject
Pareto(3.7, 0.568)	2.52E-02	reject
Extreme Value IB(52.3, 39.1)	1.15E-02	reject
Triangular(3.68, 122, 3.7)	1.01E-03	reject
Uniform(3.7, 102)	0	reject
Johnson SB	no fit	reject

S10

Distribution	rank	acceptance
Johnson SB(-23.8, 69.6, -1.78, 0.548)	100	do not reject
Beta(23.9, 45.8, 1.92, 0.683)	84.2	do not reject
Extreme Value IB(42.5, 4.62)	56.3	do not reject
Weibull(-64.3, 22.5, 107)	48.1	do not reject
Logistic(40.9, 3.87)	33.9	do not reject
LogLogistic(-6.67e+003, 1.71e+003, 6.71e+003)	33.4	do not reject
Normal(39.5, 7.33)	19.4	do not reject
Lognormal(-1.9e+003, 7.57, 3.79e-003)	19.1	do not reject
Pearson 5(-41.6, 98.3, 7.89e+003)	12.2	do not reject
Rayleigh(21.4, 13.8)	3.96	do not reject
Power Function(22., 45.8, 1.93)	1.4	do not reject
Triangular(20.3, 45.8, 45.8)	0.874	do not reject
Uniform(23.9, 45.8)	1.37E-02	reject

ANEXO II

Tabelas com os resultados do roteamento em ordem decrescente:

Resultados do modelo com roteamento discretizado						
Modelo:	cit	cft	cttr	cst	ciet	f.o.
RP	225.055	0	268.772	449.516	0	943.324
WS	221.734	0	263.183	363.618	0	848.536
EV	223.510	0	262.609	347.779	0	833.897
EEV	222.865	9.212.000	262.609	490.069	0	10.187.544

Resultados do modelo SAA com roteamento com 1 amostra									
Número de cenários:	Modelo:	cit	cft	cttr	cst	ciet	f.o.	tempo (s)	Gap
50	RP	232.923	0	288.324	458.680	3500	983.427	15,0	0%
	WS	224.264	0	276.267	354.985	0	855.517	2,215	0%
	EV	223.509	0	262.609	347.779	0	833.897	3,15	0%
	EEV	76.647	24.430.000	262.609	1.268.244	77.000	26.114.500	7,01	0%
100	RP	230.700	0	288.323	465.320	3.500	987.840	70,56	0%
	WS	222.696	0	276.185	359.872	0	858.752	11,053	0,34%
	EV	223.509	0	262.609	347.779	0	833.897	3,15	0%
	EEV	75.455	23.268.000	262.609	1.28.246	57.750	24.945.060	2,76	0%
150	RP	230.132	0	288.323	467.825	2.333	988.614	225,05	0%
	WS	222.047	0	275.048	361.969	0	859.064	11,518	0,68%
	EV	223.509	0	262.609	347.779	0	833.897	3,15	0%
	EEV	75.708	24.201.333	262.609	1.280.786	58.333	25.616.161	5,43	0%

Resultados dos limites inferiores do modelo SAA com roteamento								
Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>ctr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i> ($\alpha=5\%$)	tempo (s)
20	50	231.553	0	288.323	466.043	875	(982.007; 991.582)	344,75
	100	231.330	2.800	288.323	475.557	787	(993.114; 1.004.482)	7.999,38
	150	229.310	3.733	285.065	486.353	1.516	(1.000.219; 1.011.723)	18.107,22
100	50	231.648	2.800	288.323	468.210	700	(988.254; 995.109)	1.586,58
	100	231.465	5.040	288.323	477.350	770	(999.485; 1.006.926)	18.927,35
	150	231.147	5.646	288.323	480.318	1.178	(1.004.089; 1.009.137)	84.682,24

Resultados do modelo LHS com roteamento (dividido em 5 espaços equiprováveis)								
Número de amostras:	Número de cenários:	<i>cit</i>	<i>cft</i>	<i>ctr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i> ($\alpha=5\%$)	tempo (s)
20	50	231.775	0	288.323	433.275	0	(952.051; 954.693)	684,01
	100	231.708	0	288.323	435.042	175	(954.245; 956.255)	3.829,28
	150	232.010	0	288.323	435.457	758	(954.982; 958.113)	5.099,63
100	50	232.024	0	288.323	433.774	140	(953.494; 955.029)	2.887,16
	100	231.720	0	288.323	435.225	385	(955.113; 956.195)	32.759,87
	150	231.759	0	288.323	435.802	490	(955.777; 956.972)	93.091,20

Resultados para obtenção de limites superiores para modelo com roteamento						
Nível de Probabilidade:	<i>cit</i>	<i>cft</i>	<i>ctr</i>	<i>cst</i>	<i>ciet</i>	<i>f.o.</i>
0,90	198.327	0	314.038	469.068	0	981.434
0,91	196.250	0	314.038	475.954	0	986.244
0,95	184.677	0	314.038	514.261	0	1.012.976
0,99	151.910	0	314.038	633.534	0	1.099.484
0,999	99.173	0	314.038	918.644	0	1.331.856
0,9999	79.833	2.800.000	339.753	1.097.175	0	4.316.761

Tamanho do modelo com roteamento com e sem redução de cenários		
	400 cenários	100 cenários (<i>com backward reduction</i>)
n ^o de variáveis	80.052	20.052
n ^o de variáveis binárias ou inteiras	32.006	8.006
n ^o de restrições	120.014	30.014
melhor solução	1.059.272	1.124.910
limite inferior	1.169.440	1.124.910
tempo de processamento (s)	3.000,00	285,86