



**Miguel Angel Fernández Pérez**

**Modelos de programação matemática para o problema de  
intervenção em poços terrestres de petróleo**

**Tese de Doutorado**

Tese apresentada ao Programa de Pós-Graduação em Engenharia de  
Produção da PUC-Rio como requisito parcial para obtenção do grau de  
Doutor em Engenharia de Produção.

Orientador: Prof. Silvio Hamacher  
Co-orientador: Prof. Fabrício Oliveira

Rio de Janeiro  
Abril de 2017



**Miguel Angel Fernández Pérez**

**Modelos de programação matemática para o problema de intervenção em poços terrestres de petróleo**

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-Graduação em Engenharia de Produção da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

**Prof. Silvio Hamacher**

Orientador

Departamento de Engenharia Industrial – PUC-Rio

**Prof<sup>a</sup>. Luciana de Souza Pessoa**

Departamento de Engenharia Industrial – PUC-Rio

**Prof<sup>a</sup>. Laura Silvia Bahiense da Silva Leite**

Universidade Federal do Rio de Janeiro – COPPE/UFRJ

**Prof. Paulo Cesar Ribas**

Cenpes/Petrobras

**Prof. Rafael Martinelli Pinto**

Departamento de Engenharia Industrial – PUC-Rio

**Prof. Márcio da Silveira Carvalho**

Coordenador Setorial do Centro

Técnico Científico – PUC-Rio

Rio de Janeiro, 20 de abril de 2017

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

### **Miguel Angel Fernández Pérez**

Graduou-se em Engenharia Industrial na UNMSM (Universidad Nacional Mayor de San Marcos) de Lima, Perú, no ano 2007. Obteve o título de mestre em Engenharia de Produção pela PUC-Rio no ano 2012. Possui experiência profissional nas áreas de Produção, Planejamento, Orçamentos e Projetos.

#### Ficha Catalográfica

Fernández Pérez, Miguel Angel

Modelos de programação matemática para o problema de intervenção em poços terrestres de petróleo / Miguel Angel Fernández Pérez ; orientador: Silvio Hamacher ; co-orientador: Fabrício Oliveira. – 2017.

93 f. : il. color. ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Industrial, 2017.

Inclui bibliografia

1. Engenharia Industrial – Teses. 2. Sondas workover. 3. Itinerário de sondas. 4. Dimensionamento de frota de sondas. 5. Programação linear inteira. 6. Programação estocástica. I. Hamacher, Silvio. II. Oliveira, Fabrício. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Industrial. IV. Título.

CDD: 658.5

## Agradecimentos

Em primeiro lugar agradeço ao Professor Silvio Hamacher, por ter aceitado orientar minha tese de doutorado, pelos ensinamentos, pelo apoio mostrado e contribuições durante a elaboração deste trabalho.

Agradeço ao meu co-orientador Professor Fabrício Oliveira, que contribuiu com seus ensinamentos e experiência em muitos aspectos na elaboração do trabalho.

À CAPES e à PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Aos professores do Departamento de Engenharia Industrial, os quais ajudaram na minha formação acadêmica.

Também, aos meus amigos de pós-graduação da PUC-Rio.

E finalmente, agradeço aos meus pais Guzmán e Dionicia, aos meus irmãos Aldo e Arturo e a toda minha família que sempre me apoiaram durante os anos de estadia no Brasil.

## Resumo

Pérez, Miguel Angel Fernández; Hamacher, Silvio (Orientador); Oliveira, Fabrício (Co-orientador). **Modelos de programação matemática para o problema de intervenção em poços terrestres de petróleo**. Rio de Janeiro, 2017. 93p. Tese de Doutorado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

Na indústria do petróleo e gás, uma das atividades de maior importância é a intervenção em poços para serviços de manutenção, a qual é necessária para garantir a produção de petróleo. Estas intervenções são realizadas por sondas *workover* que são disponibilizadas para atender uma grande quantidade de poços segundo um itinerário. Nesta tese são propostos três modelos de programação linear inteira para abordar eficientemente o problema de intervenção em poços terrestres de petróleo. O primeiro modelo determina o itinerário de um conjunto de sondas homogêneas, visando minimizar a perda total de produção. Este modelo é um aprimoramento do modelo proposto por Costa e Ferreira Filho (2004). O segundo modelo é uma extensão do anterior e considera também o dimensionamento de uma frota de sondas heterogênea, procurando minimizar o custo de perda de produção e o custo de aluguel de sondas. O terceiro modelo é uma abordagem estocástica que estende o segundo modelo e consiste em dimensionar uma frota de sondas considerando o tempo de intervenção incerto. A incerteza do tempo de intervenção é representada mediante a geração de cenários, usando para este fim os métodos de *Monte Carlo*, Redução de Cenários e *Quasi-Monte Carlo*. Os testes de estabilidade propostos por Kaut e Wallace (2003) são aplicados para avaliar os métodos de geração de cenários e estabelecer o número de cenários adequados para resolver o problema. Para avaliar o desempenho dos modelos propostos, diversos experimentos computacionais foram realizados em instâncias de pequeno, médio e grande porte. Todas as instâncias são baseadas em casos reais no Brasil. Os resultados mostram que os modelos propostos foram capazes de resolver todas as instâncias utilizadas, inclusive aquelas de grande porte, demonstrando serem eficientes quando comparadas com várias metaheurísticas, pois produzem soluções exatas em um curto tempo computacional. Uma análise do impacto nas soluções quando ocorre uma

mudança no preço de petróleo e no horizonte de planejamento também é realizada. A metodologia de resolução empregada no terceiro modelo mostrou que o método *Quasi-Monte Carlo* proporcionou os melhores cenários para representar a incerteza e também o potencial do modelo para resolver problemas de grande porte.

## **Palavras-chave**

Sondas *workover*; itinerário de sondas; dimensionamento de frota de sondas; programação linear inteira; programação estocástica.

## Abstract

Pérez, Miguel Angel Fernández; Hamacher, Silvio (Advisor); Oliveira, Fabrício (Co-advisor). **Mathematical programming models for the problem of intervention in onshore oil wells**. Rio de Janeiro, 2017. 93p. Tese de Doutorado – Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

In the oil and gas industry, one of the most important activities is the intervention in wells for maintenance services, which is necessary to ensure the production of oil. These interventions are performed by workover rigs that are available to serve a large number of wells according to a schedule. In this thesis, we proposed three integer linear programming models to efficiently address the problem of intervention in onshore oil wells. The first model determines the schedule of a set of homogeneous rigs, with the objective of minimizing the total production loss. This model is an improvement of the model proposed by Costa and Ferreira Filho (2004). The second model is an extension of the previous one and also considers the sizing of a heterogeneous rig fleet, with the objective of minimizing the production loss cost and the rig rental cost. The third model is a stochastic approach that extends the second model and consists of sizing a rig fleet considering the uncertainty in the intervention time. The uncertainty in the intervention time is represented by the generation of scenarios, using for this purpose the Monte Carlo, Scenario Reduction, and Quasi-Monte Carlo methods. The stability tests proposed by Kaut and Wallace (2003) are applied to evaluate the scenario generation methods and to establish the number of appropriate scenarios to solve the problem. To evaluate the performance of the proposed models, several computational experiments were performed in small, medium and large instances. All instances are based on real cases in Brazil. The results show that the proposed models were able to solve all of the instances considered, including the large instances, proving to be efficient when compared to various metaheuristics, as they produce exact solutions in small computational time. An analysis of the impact on the solutions when there is a change in the oil price and the planning horizon is also carried out. The resolution methodology employed in the third model showed that the Quasi-Monte Carlo method provided the best

scenarios to represent the uncertainty and also the potential of the model to solve large-scale problems.

## **Keywords**

Workover rigs; rig scheduling; rig fleet sizing; integer linear programming; stochastic programming.

## Sumário

1. Introdução	14
1.1. Descrição dos objetivos	15
1.2. Estrutura da tese	17
2. Intervenção em poços terrestres de petróleo	18
3. Problema de otimização de itinerário de sondas para poços terrestres de petróleo	22
3.1. Descrição do problema	24
3.2. Formulação do problema	25
3.2.1. Modelo matemático original	26
3.2.2. Modelo matemático decomposto	26
3.2.3. Comparação entre o MMO e o MMD	32
3.3. Experimentos computacionais	32
3.3.1. Grupo de Instâncias N.1	33
3.3.2. Grupo de Instâncias N.2	38
4. Problema de otimização de itinerário e dimensionamento de frota de sondas para poços terrestres de petróleo	41
4.1. Descrição do problema	42
4.2. Formulação do problema	43
4.3. Experimentos computacionais	49
5. Problema de otimização de itinerário e dimensionamento de frota de sondas sob incerteza para poços terrestres de petróleo	53
5.1. Modelo de programação estocástica de dois estágios	54
5.2. Métodos de geração de cenários	56
5.2.1. Método <i>Monte Carlo</i>	56
5.2.2. Método de Redução de Cenários	57
5.2.3. Método <i>Quasi-Monte Carlo</i>	58
5.3. Avaliação do método de geração de cenários	59
5.3.1. Teste de estabilidade <i>In-sample</i>	59
5.3.2. Teste de estabilidade <i>Out-of-sample</i>	60
5.4. Descrição do problema	60

5.5. Formulação do problema	61
5.6. Experimentos computacionais	63
5.6.1. Instância N.1	65
5.6.2. Instância N.2	73
5.6.3. Instância N.3	76
6. Conclusões e trabalhos futuros	81
7. Referências bibliográficas	84
8. Apêndice	93

## Lista de tabelas

Tabela 1 – Comparação do número de restrições e número de variáveis do MMO e MMD	32
Tabela 2 – Resultados da relaxação linear aplicado ao MMO e MMD	34
Tabela 3 – Resultados computacionais dos diferentes métodos empregados no Grupo de Instâncias N.1	35
Tabela 4 – Tempos computacionais (s) dos diferentes métodos empregados no Grupo de Instâncias N.1	37
Tabela 5 – Resultados computacionais do MMD no Grupo de Instâncias N.2	39
Tabela 6 – Resultados computacionais do MMD com $\alpha = \text{US\$ } 250/\text{m}^3$	50
Tabela 7 – Resultados computacionais do MMD com $\alpha = \text{US\$ } 350/\text{m}^3$	51
Tabela 8 – Resultados computacionais da análise preliminar com 10 cenários da Instância N.1	66
Tabela 9 – Resultados computacionais da análise preliminar com 20 cenários da Instância N.1	67
Tabela 10 – Resultados computacionais da análise preliminar com 30 cenários da Instância N.1	68
Tabela 11 – Resultados computacionais com 50 cenários da Instância N.1	69
Tabela 12 – Resultados computacionais com 100 cenários da Instância N.1	69
Tabela 13 – Resultados computacionais com 200 cenários da Instância N.1	70
Tabela 14 – Resultados computacionais para a Instância N.2	74
Tabela 15 – Resultados computacionais para a Instância N.3	77
Tabela 16 – Estatísticas das instâncias N.1, N.2 e N.3	80

## Lista de figuras

Figura 1 – Sonda <i>workover</i>	19
Figura 2 – Transporte de uma sonda <i>workover</i>	20
Figura 3 – Exemplo de representação das variáveis de decisão	27
Figura 4 – Exemplo da representação do nível de serviço das sondas e dos poços	43
Figura 5 – Exemplo de uma amostra bidimensional <i>Monte Carlo</i>	57
Figura 6 – Exemplo do método de Redução de Cenários de uma amostra bidimensional	58
Figura 7 – Exemplo de uma amostra bidimensional <i>Quasi-Monte Carlo</i>	59
Figura 8 – Exemplo de geração de cenários para realizar os testes <i>in-sample</i> e <i>out-of-sample</i>	64
Figura 9 – Metodologia para realizar os testes <i>in-sample</i> e <i>out-of-sample</i>	65
Figura 10 – Custo esperado do método MC para os testes de estabilidade da Instância N.1	71
Figura 11 – Custo esperado do método de RC para os testes de estabilidade da Instância N.1	71
Figura 12 – Custo esperado do método QMC para os testes de estabilidade da Instância N.1	72
Figura 13 – Desvio do Custo do método MC, RC e QMC para o teste de estabilidade <i>in-sample</i> da Instância N.1	72
Figura 14 – Desvio do Custo do método MC, RC e QMC para o teste de estabilidade <i>out-of-sample</i> da Instância N.1	72
Figura 15 – Custo esperado do método QMC para os testes de estabilidade da Instância N.2	75
Figura 16 – Desvio do Custo do método QMC para o teste de estabilidade <i>in-sample</i> da Instância N.2	76
Figura 17 – Desvio do Custo do método QMC para o teste de estabilidade <i>out-of-sample</i> da Instância N.2	76

Figura 18 – Custo esperado do método QMC para os testes de estabilidade da Instância N.3	78
Figura 19 – Desvio do Custo do método QMC para o teste de estabilidade <i>in-sample</i> da Instância N.3	78
Figura 20 – Desvio do Custo do método QMC para o teste de estabilidade <i>out-of-sample</i> da Instância N.3	79
Figura 21 – Tempo de execução médio <i>in-sample</i> para as instâncias N.1, N.2 e N.3	80

# 1 Introdução

Na atualidade, o petróleo movimenta bilhões de dólares diariamente, compondo uma gigantesca indústria e, além de produzir combustíveis, é utilizado para produzir centenas de produtos derivados como plásticos, borrachas sintéticas, tintas, corantes, adesivo, solventes, detergentes, explosivos, produtos farmacêuticos, cosméticos e outros. Numerosos recursos são alocados para seu desenvolvimento e pesquisa, surgindo a cada dia novas tecnologias e equipamentos para a descoberta de novas jazidas, produção, transporte e refino (Thomas, 2001).

O mercado de petróleo é muito competitivo, e por se tratar de um recurso não renovável, sua exploração deve ser feita de maneira eficiente, de modo que os custos sejam reduzidos e as jazidas melhor aproveitadas. Por isso, problemas relacionados com a produção de petróleo vêm se tornando um grande desafio para as empresas (Neves, 2007).

Durante a produção nos campos petrolíferos, usualmente é necessário realizar o bombeio de fluidos para que o petróleo atinja a superfície. Em consequência disso, se faz necessário a instalação de equipamentos que realizem o bombeio nos poços. Ao longo do tempo, esses equipamentos sofrem falhas, fazendo com que os poços precisem de serviços de manutenção (denominados *workover*), tais como limpeza, restauração, estimulação e outros, que visam manter a produção ou melhorar a produtividade do poço. Estas intervenções nos poços são executadas por sondas *workover*.

As sondas são recursos limitados e escassos, com elevados custos de operação e que devem atender um grande número de poços que demandam por serviços de manutenção. Por isso, deve ser definido um itinerário de atendimento aos poços que evite altas perdas de produção, causadas por poços inativos à espera de serviços de manutenção.

Segundo Accioly e Chiyoshi (1998), um número grande de sondas disponíveis reduz altamente o efeito das falhas nos poços. Porém, as sondas são recursos caros, de modo que um número excessivo destas eleva os custos de operação, o qual é indesejável. Uma decisão cuidadosa do número adequado de

sondas requer a quantificação da relação entre o nível de produção de petróleo e o número de sondas usadas. Na mesma linha, Bissoli et al. (2016) consideram que devido aos altos custos de aluguel de sondas, um enfoque que relacione a quantidade de sondas e o custo de perda de produção pode ser útil para analisar o *tradeoff* entre alugar mais sondas e obter economias devido à restauração da produção.

Irgens e Lavenue (2007) destacam a importância de implementar uma ferramenta computacional eficaz, que sirva de apoio diário aos profissionais encarregados do planejamento e operações de sondas para serviços de perfuração e manutenção de poços, que vise otimizar o itinerário de sondas e inclusive reprogramá-lo quando mudanças operacionais ocorram (mudanças climáticas, equipamentos não disponíveis, variação do volume de produção de alguns poços, etc.).

Costa (2005) apresentou um estudo de caso a partir de dados reais de uma companhia brasileira, no qual o itinerário de sondas é monitorado e definido por meio de uma reunião semanal com representantes de alguns departamentos. Quatro itinerários reais foram selecionados e uma heurística foi testada nesses casos. Esta heurística melhorou as soluções encontradas pelos profissionais da companhia, produzindo um ganho de 21 mil barris, o que significou cerca de 2,3 milhões de dólares de economia.

Aloise et al. (2006) reportaram resultados computacionais de 8 casos reais proporcionados por uma companhia brasileira. Uma heurística aplicada obteve um aumento de 2673 barris, equivalente a 107 mil dólares com relação à solução implementada pelos profissionais da companhia.

Portanto, proporcionar soluções ótimas para o problema é uma iniciativa que pode levar a milhões de dólares de economia devido à redução da perda de produção de barris de petróleo.

## **1.1 Descrição dos objetivos**

O objetivo principal da presente tese é desenvolver modelos de programação matemática capazes de resolver eficientemente o problema de intervenção em poços terrestres de petróleo, isto é, modelos matemáticos que

possam obter soluções ótimas de instâncias de grande porte em um curto ou reduzido tempo computacional. Estes modelos são baseados no enfoque de escalonamento de máquinas em paralelo. O primeiro modelo é focado em determinar o itinerário de um conjunto de sondas homogêneas, visando minimizar a perda total de produção. O segundo modelo é uma extensão do anterior e considera também o dimensionamento de uma frota de sondas heterogêneas, procurando minimizar o custo da perda de produção de petróleo e o custo de aluguel de sondas ou alocação de sondas em uma região. O terceiro modelo é uma abordagem estocástica do segundo modelo, considerando a incerteza do tempo de intervenção.

O primeiro modelo tem como objetivo comparar sua eficiência com várias metaheurísticas disponíveis na literatura, mediante a resolução de instâncias de pequeno, médio e grande porte.

O segundo modelo tem como objetivo analisar o impacto no tamanho de frota de sondas, quando variações no preço de petróleo e no horizonte de tempo são realizadas, com a vantagem de obter resultados ótimos em um curto tempo computacional.

No terceiro modelo, para o problema estocástico, é usado uma avaliação dos métodos de geração de cenários, proposta por Kaut e Wallace (2003), para garantir a estabilidade dos resultados encontrados. Os métodos de geração de cenários utilizados são o *Monte Carlo*, Redução de Cenários e *Quasi-Monte Carlo*. O objetivo desta análise é desenvolver uma metodologia que possa resolver esta classe complexa de problemas (devido ao elevado aumento de número de restrições e variáveis pela definição de cenários da variável aleatória) com pouco esforço computacional. Adicionalmente, tem-se como objetivo determinar a melhor opção entre os métodos de geração de cenários para o problema.

Pode ser destacado como objetivo secundário a proposição de novas instâncias baseadas em casos reais, que possam ser aplicadas no segundo e terceiro modelo, as quais são mais aproximadas a um contexto real de operação. A geração de novas instâncias é um assunto relevante, dado que existe uma quantidade reduzida destas na literatura.

## 1.2 Estrutura da tese

A presente tese é composta de 6 capítulos. No Capítulo 1, foram apresentadas a introdução do problema e a descrição dos objetivos, ilustrando a relevância do estudo.

No Capítulo 2 são descritas as atividades de intervenção em poços terrestres de petróleo, onde são apresentadas as características operacionais de um campo de petróleo e é discutida a complexidade do problema de intervenção em poços.

No Capítulo 3 é apresentado o Problema de Otimização de Itinerário de Sondas para poços terrestres de petróleo. O capítulo inicia com a revisão literária, ressaltando as várias heurísticas e metaheurísticas aplicadas ao problema. Em seguida, são apresentadas a descrição do problema, a formulação proposta e os experimentos computacionais realizados. Nos experimentos computacionais, o primeiro modelo matemático proposto é aplicado em várias instâncias da literatura, e comparado com diversas metaheurísticas e com o modelo proposto por Costa e Ferreira Filho (2004).

No Capítulo 4 é apresentado o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas para poços terrestres de petróleo. O capítulo faz uma breve revisão da literatura e em seguida descreve o problema, a formulação proposta e apresenta os experimentos computacionais. Nos experimentos computacionais, instâncias aleatórias são utilizadas para avaliar o desempenho do segundo modelo matemático proposto.

No Capítulo 5 é apresentado o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas sob incerteza para poços terrestres de petróleo. O capítulo descreve os enfoques para abordar o problema na literatura, define o modelo de programação estocástica de dois estágios, os métodos de geração e avaliação de cenários, apresenta a descrição do problema, a formulação proposta e os experimentos computacionais. Nos experimentos computacionais, três instâncias aleatórias são utilizadas para avaliar o desempenho do terceiro modelo matemático proposto.

Finalmente no Capítulo 6, as conclusões deste trabalho e as sugestões para futuras pesquisas são discutidas.

## 2 Intervenção em poços terrestres de petróleo

Para que os poços terrestres possam começar a operar é necessário a instalação de equipamentos para a elevação do petróleo. A elevação de fluidos é realizada por diversas técnicas artificiais, tais como: bombeio mecânico, bombeio por cavidades progressivas, *gas lift*, dentre outros. Ao longo do tempo, esses equipamentos sofrem falhas, fazendo com que os poços necessitem de serviços de manutenção, que visam manter a produção ou melhorar a produtividade do poço. De acordo a Thomas (2001), estas intervenções são classificadas como:

- Avaliação: destinada a medir os parâmetros dos reservatórios e diagnosticar causas de baixa produtividade;
- Recompletação: visa substituir as zonas que estavam em produção ou colocar novas zonas em produção. A recompletação também é realizada quando se deseja converter um poço produtor em injetor (água, gás, vapor, etc.), ou vice-versa;
- Restauração: visa restabelecer as condições normais de fluxo do reservatório para o poço, corrigir falhas mecânicas no revestimento ou cimentação e reduzir a produção excessiva de água ou gás;
- Limpeza: conjunto de atividades executadas no interior do revestimento para limpar o fundo do poço ou substituir equipamentos;
- Mudança do método de elevação: consiste em substituir um sistema de elevação artificial inadequado ou com defeito;
- Estimulação: conjunto de atividades que tem como objetivo aumentar a produtividade ou injetividade do poço;
- Abandono: quando um poço é retirado de operação e deve ser tamponado, podendo ser provisório ou definitivo.

Cada serviço de manutenção tem um tempo específico para execução e, portanto, a classe de serviço é importante para a definição do itinerário de sondas. Por exemplo, serviços de recompletação e restauração são procedimentos longos que podem variar entre 5 a 15 dias, outros serviços como limpeza e estimulação

podem ser realizados no máximo em dois dias (Bissoli et al., 2016). Adicionalmente, a construção do itinerário deve considerar fatores como a produção do poço, a janela de tempo disponível para a realização do serviço, o nível de serviço da sonda e o nível de serviço requerido do poço (Aloise et al., 2006).

Os serviços de manutenção são executados por sondas *workover* como mostra a Figura 1.



Figura 1 – Sonda *workover*  
Fonte: Sabry (2012, p. 27)

A utilização de sondas em poços de petróleo é dada principalmente para atividades de perfuração e manutenção. No primeiro caso, uma sonda de perfuração requer um tempo prolongado para terminar os trabalhos e o itinerário desta classe de sondas pode ser alterado ligeiramente, pois envolve decisões estratégicas. No segundo caso, as sondas *workover* não exigem muito tempo na execução de intervenções, pois devem manter os poços em produção, executando as atividades planejadas de forma otimizada (Bissoli et al., 2016).

Em um campo de petróleo terrestre, geralmente o horizonte de tempo considerado para planejar atividades de manutenção em poços é de 15 dias (Aloise et al., 2006; Duhamel, Santos & Guedes, 2012). No entanto, nem sempre todos os poços são atendidos pelas sondas dentro do prazo estipulado. Os poços não atendidos são adiados para um próximo planejamento junto com novos poços que possam requerer serviços. Assim, a perda total de produção considera a perda

dos poços atendidos e não atendidos dentro do horizonte de tempo (Ribeiro, Desaulniers & Desrosiers, 2012; Sabry, 2012).

Na prática as sondas *workover* podem ser heterogêneas ou homogêneas, devido aos vários níveis de manutenção que podem realizar (Duhamel, Santos & Guedes, 2012). Segundo Soares et al. (2011) as sondas de níveis maiores são capazes de realizar todos os serviços das de níveis menores, uma vez que todas as especificações apresentadas das sondas maiores apontam para uma igual ou maior capacidade. Por exemplo, as sondas variam de acordo com a profundidade que podem atingir.

O transporte de sondas é realizado por caminhões carreta, como mostra a Figura 2. Estes caminhões podem atingir uma velocidade de 30 km/h aproximadamente nas estradas (Paiva, 1997; Maia et al., 2002).



Figura 2 – Transporte de uma sonda *workover*  
Fonte: Aloise et al. (2006, p. 696)

O problema de intervenção em poços terrestres de petróleo pode ser tratado como um problema de escalonamento com máquinas em paralelo ou como um problema de roteamento com múltiplos veículos. No enfoque de escalonamento, os tempos de transporte entre poços pela sonda são desconsiderados para fins práticos. Já no enfoque de roteamento, os tempos de transporte são considerados significativos. Quanto à complexidade do problema, é sabido que ambos os enfoques são de natureza combinatória e pertencentes à classe *NP-hard* (Du & Leung, 1990; Tsitsiklis, 1992).

Segundo Gouvêa et al. (2002), o uso do enfoque de escalonamento é apropriado nos casos onde os tempos necessários para movimentar as sondas entre os poços são da ordem de minutos e os tempos de intervenção são da ordem de dias ou semanas.

Por exemplo, a empresa brasileira PETROBRAS possui uma unidade de negócios na bacia de São Mateus, no norte de Espírito Santo, a qual é composta por centenas de poços distribuídos em dezenas de campos. A pesquisa realizada por Costa (2005) a partir do histórico de intervenções ocorridas no ano 2004 mostra que a duração da intervenção é de dois dias em média. Adicionalmente reporta que os poços se encontram distantes 20 km em média entre si, isto equivale 40 min de transporte aproximadamente. Com isto, o autor considera que o enfoque de escalonamento é o mais adequado.

Outro estudo realizado na empresa PETROBRAS, na bacia de Potiguar localizada na região nordeste do Brasil, é apresentado por Aloise et al. (2006). Os autores reportam que executar as intervenções toma 4 dias em média e 14 dias no máximo. Também que o transporte das sondas é realizado em 2 horas em média e 5 horas no máximo. Nestas condições, os autores consideram que o enfoque de roteamento é o mais adequado.

Nesta tese, o enfoque de escalonamento é utilizado, tomando como base a pesquisa de Costa (2005) por possuir um grupo de instâncias bem definidas (em valores e unidades de medida) e por ser fonte de referência de diversos trabalhos focados em heurísticas e metaheurísticas.

No próximo capítulo é apresentado o primeiro modelo matemático proposto, o qual determina o itinerário de um conjunto de sondas homogêneas, visando minimizar a perda total de produção.

### 3

## Problema de otimização de itinerário de sondas para poços terrestres de petróleo

Smith (1956) foi o primeiro autor a abordar Problema de Otimização de Itinerário de Sondas. Ele demonstrou que se o problema tem apenas uma sonda e não apresenta janelas de tempo, o itinerário ótimo é quando os poços são ordenados em forma decrescente em relação a  $p_i/d_i$ , onde  $p_i$  é a vazão de petróleo do poço  $i$  e  $d_i$  é o tempo da intervenção no poço  $i$ . Este itinerário é chamado de Ordem Natural.

Barnes et al. (1977) mostraram que um limite inferior com  $N$  sondas e  $J$  poços é dado pelo maior valor entre  $B(J)$  e  $LB = \frac{1}{2N}[(N - 1)B(J) + 2B(1)]$ , onde  $B(1)$  é a perda total de produção com apenas uma sonda e  $B(J)$  a perda total de produção com  $J$  sondas (uma sonda por cada poço).

Paiva (1997) e Paiva et al. (2000) apresentaram um estudo empregando um simulador de reservatórios para analisar a influência monetária no cálculo da perda de produção devido ao fechamento de poços quando uma falha é detectada.

Costa e Ferreira Filho (2004) propuseram um modelo de programação linear inteira 0-1 e implementaram uma heurística baseada na Ordem Natural. Costa (2005) implementou uma metaheurística *Greedy Randomized Adaptive Search Procedure* (GRASP) e construiu um grupo de instâncias baseadas em casos reais de um campo terrestre de petróleo no Brasil. As instâncias geradas por Costa (2005) são amplamente utilizadas na literatura em diversas heurísticas e metaheurísticas (Costa & Ferreira Filho, 2005; Alves & Ferreira Filho, 2006; Oliveira et al., 2007; Pacheco et al., 2009; Douro & Lorenzoni, 2009; Pacheco et al., 2010; Pacheco, 2011; Ribeiro et al., 2011). Apesar destas metaheurísticas tenham bons resultados para instâncias de pequeno e médio porte (instâncias com menos de 75 poços), estas não são capazes de atingir valores ótimos para instâncias de grande porte (instâncias com mais de 100 poços). Pérez et al. (2016) propuseram um aprimoramento do modelo de Costa e Ferreira Filho (2004), conseguindo resolver de maneira ótima e um tempo computacional reduzido todas

instâncias construídas por Costa (2005), inclusive aquelas de grande porte que eram desconhecidas até então.

Aloise et al. (2006) propuseram uma heurística *Variable Neighborhood Search* (VNS). Os autores empregaram uma heurística construtiva para gerar soluções iniciais, definindo nove diferentes vizinhanças para a busca de melhores soluções. Foram usados dados de casos reais no Brasil. Neves (2007) propôs as metaheurísticas GRASP, GRASP com uso de técnicas de memórias adaptativas, *Tabu Search* (TS) e *Iterated Local Search* (ILS). Estas heurísticas foram testadas em um grupo instâncias geradas aleatoriamente.

Ribeiro et al. (2011) aplicaram um *Simulated Annealing* (SA) com três movimentos para compor a estrutura de vizinhança. Ribeiro, Laporte e Mauri (2012) aplicaram as heurísticas *Clustering Search* (CS) e *Adaptive Large Neighborhood Search* (ALNS), comparando os resultados com o ILS proposto por Neves (2007). Ribeiro, Desaulniers e Desrosiers (2012) apresentaram um modelo matemático para este problema e um algoritmo *Branch Price & Cut* (BPC). Para testar o algoritmo foi gerado um grupo de instâncias aleatórias a partir das instâncias propostas por Neves (2007).

Duhamel, Santos e Guedes (2012) propuseram três modelos de programação inteira-mista. O primeiro é um melhoramento de um modelo proposto por Aloise et al. (2006); o segundo é baseado no *Open Vehicle Routing Model*; e o terceiro baseado no *Set Covering Model*, incorporando neste a estratégia de geração de colunas. Para testar os modelos foram geradas instâncias usando características reais de um campo terrestre de petróleo no Brasil. Ribeiro et al. (2014) apresentaram uma heurística BPC e um *Hybrid Genetic Algorithm* (HGA) para resolver o problema. Monemi et al. (2015) propuseram um modelo de programação linear inteira-mista. O modelo incorpora uma *hyper-heuristic*, a qual gera uma escolha adequada de movimentos no espaço de heurísticas. O resultado da *hyper-heuristic* é usado para a geração de colunas de um algoritmo BPC. Os experimentos numéricos foram realizados em dados aleatoriamente gerados em um campo de petróleo no Brasil.

A seguir será descrito o Problema de Otimização de Itinerário de Sondas para poços terrestres de petróleo e apresentado o primeiro modelo matemático proposto. Nos experimentos computacionais, este modelo foi testado em diversas

instâncias, e comparado com o modelo proposto por Costa e Ferreira Filho (2004) e com várias metaheurísticas disponíveis na literatura.

### 3.1 Descrição do problema

O problema apresentado neste capítulo é descrito como segue: dado um conjunto de sondas  $n = 1, \dots, N$  e um conjunto de poços  $i = 1, \dots, J$  que requerem serviços de manutenção, onde cada poço  $i$  está associado a um tempo de intervenção  $d_i$ ; uma janela de tempo no intervalo  $[a_i, b_i]$  no qual poderá ser atendido; e um valor de vazão de petróleo  $p_i$  que indica quanto aquele poço deixará de produzir (em unidades de volume por unidade de tempo). A execução de cada intervenção em um poço requer que uma sonda seja selecionada. Dessa forma, o Problema de Otimização de Itinerário de Sondas (POIS) para poços terrestres de petróleo consiste em determinar o itinerário de atendimento aos poços pelas sondas com o objetivo de minimizar a perda total de produção de petróleo devido à espera dos poços por serviço de manutenção em um horizonte de tempo.

As hipóteses consideradas são:

- A frota de sondas é homogênea.
- Os tempos de transporte das sondas entre cada par de poços não são considerados, uma vez que não são significativos em relação aos tempos de intervenção.
- Os tempos de montagem e desmontagem estão incluídos no tempo de intervenção.
- Cada sonda começa a operar no início do horizonte e trabalha sem tempos ociosos até que todos os poços alocados na sonda sejam atendidos.
- Uma vez iniciada a intervenção, a mesma não pode ser interrompida.

### 3.2 Formulação do problema

Nesta seção é apresentado o modelo matemático proposto por Costa e Ferreira Filho (2004) e a continuação é desenvolvido o primeiro modelo matemático proposto. A seguinte notação dos índices, parâmetros e variáveis de decisão é usada para formular o POIS:

#### Índices

$i, j$ : Índice de poços,  $i, j = \{1, 2, \dots, J\}$

$n$ : Índice de sondas,  $n = \{1, 2, \dots, N\}$

$t, h$ : Índice de tempo,  $t, h = \{1, 2, \dots, T\}$

#### Parâmetros

$J$ : Número de poços

$N$ : Número de sondas

$T$ : Horizonte de tempo

$p_i$ : Vazão de petróleo do poço  $i$

$d_i$ : Duração da intervenção no poço  $i$

$[a_i, b_i]$ : Janela de tempo, onde  $a_i$  é o tempo mais cedo que pode começar a intervenção no poço  $i$  e  $b_i$  é o limite de tempo para terminar a intervenção no poço  $i$

#### Variáveis

$S_{int} = \begin{cases} 1, & \text{se a sonda } n \text{ inicia a execução do serviço do poço } i \text{ no tempo } t \\ 0, & \text{caso contrário} \end{cases}$

$C_{int} = \begin{cases} 1, & \text{se a sonda } n \text{ termina a execução do serviço do poço } i \text{ no tempo } t \\ 0, & \text{caso contrário} \end{cases}$

$X_{int} = \begin{cases} 1, & \text{se a sonda } n \text{ está executando o serviço do poço } i \text{ no tempo } t \\ 0, & \text{caso contrário} \end{cases}$

$SD_{it} = \begin{cases} 1, & \text{se a execução do serviço do poço } i \text{ inicia no tempo } t \\ 0, & \text{caso contrário} \end{cases}$

### 3.2.1 Modelo matemático original

Costa e Ferreira Filho (2004) propuseram um modelo de programação linear inteira 0-1, chamado aqui de Modelo Matemático Original (MMO). O modelo é formulado com a variável binária  $S_{int}$ , que toma valor 1 se a sonda  $n$  inicia o serviço do poço  $i$  no tempo  $t$  e toma valor 0 caso contrário. O MMO é apresentado a seguir:

$$(MMO) \text{ Min } \sum_{i=1}^J \sum_{n=1}^N \sum_{t=1}^T (t + d_i - a_i) p_i S_{int} \quad (1)$$

Sujeito a:

$$\sum_{n=1}^N \sum_{t=1}^T S_{int} = 1 \quad \forall i \quad (2)$$

$$\sum_{i=1}^J S_{int} \leq 1 \quad \forall n, t \quad (3)$$

$$S_{int} + S_{jnh} \leq 1 \quad \forall i, j, n, t, h | i \neq j \text{ e } t \leq h \leq t + d_i - 1 \quad (4)$$

$$S_{int} \in \{0,1\} \quad \forall i, n, t | a_i \leq t \leq b_i - d_i + 1 \quad (5)$$

Neste modelo matemático, a função objetivo (1) representa a minimização da perda total de produção. A restrição (2) assegura que o início da intervenção em cada poço ocorra apenas uma vez por uma sonda. A restrição (3) garante que uma sonda, em um tempo específico, inicie no máximo uma intervenção. A restrição (4) assegura que não exista interferência entre os serviços nos poços que utilizam a mesma sonda, isto é, nenhum poço  $j$  pode ser atendido no intervalo  $[t, t + d_i - 1]$  pela sonda  $m$  se o poço  $i$  está sendo atendido nesse intervalo pela mesma sonda  $m$ . A restrição (5) define o domínio das variáveis de decisão e assegura que o início das intervenções nos poços seja dentro da janela de tempo.

### 3.2.2 Modelo matemático decomposto

Neste trabalho é proposto uma nova formulação para o POIS baseada no MMO, o qual é apresentado como um Modelo Matemático Decomposto (MMD).

O MMD será deduzido a partir de um modelo matemático, inicialmente maior, utilizando além da variável  $S_{int}$ , duas novas variáveis binárias  $C_{int}$  e  $X_{int}$ , que representam se a sonda  $n$  termina ou está executando o serviço do poço  $i$  no tempo  $t$  respectivamente.

A Figura 3 ilustra a representação das variáveis  $S_{int}$ ,  $C_{int}$  e  $X_{int}$ . Suponha que certa intervenção  $i$  começa em  $t = 3$  ( $S_{in3} = 1$ ); se a duração da intervenção é 4 ( $d_i = 4$ ) então o fim da intervenção será em  $t = 6$  ( $C_{in6} = 1$ ), isto é, a sonda permanece no poço  $i$  em  $3 \leq t \leq 6$  ( $X_{in3} = X_{in4} = X_{in5} = X_{in6} = 1$ ). Portanto, pode-se inferir que  $C_{int} = S_{in,t-d_i+1}$ .

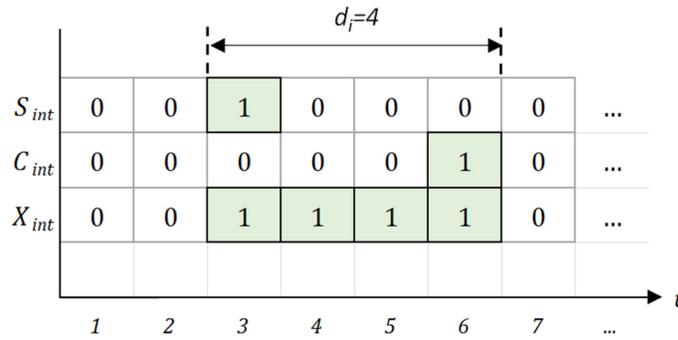


Figura 3 – Exemplo de representação das variáveis de decisão  
Fonte: Elaborado pelo autor

Com a inclusão dessas novas variáveis, o POIS é formulado como segue:

$$\text{Min} \sum_{i=1}^J \sum_{n=1}^N \sum_{t=1}^T (t + d_i - a_i) p_i S_{int} \quad (6)$$

Sujeito a:

$$\sum_{n=1}^N \sum_{t=1}^T S_{int} = 1 \quad \forall i \quad (7)$$

$$\sum_{i=1}^J S_{int} \leq 1 \quad \forall n, t \quad (8)$$

$$S_{int} = 0 \quad \forall i, n, t | t < a_i \text{ ou } t > b_i - d_i + 1 \quad (9)$$

$$\sum_{n=1}^N \sum_{t=1}^T C_{int} = 1 \quad \forall i \quad (10)$$

$$\sum_{i=1}^J C_{int} \leq 1 \quad \forall n, t \quad (11)$$

$$C_{int} = 0 \quad \forall i, n, t | t < a_i + d_i - 1 \text{ ou } t > b_i \quad (12)$$

$$C_{int} = S_{in,t-d_i+1} \quad \forall i, n, t \quad (13)$$

$$X_{int} = \sum_{h=1}^t S_{inh} - \sum_{h=1}^{t-1} C_{inh} \quad \forall i, n, t \quad (14)$$

$$\sum_{i=1}^J X_{int} \leq 1 \quad \forall n, t \quad (15)$$

$$S_{int}, C_{int}, X_{int} \in \{0,1\} \quad \forall i, n, t \quad (16)$$

Neste modelo matemático, a função objetivo (6) representa a minimização da perda total de produção. A restrição (7) assegura que o início da intervenção em cada poço ocorra apenas uma vez por uma sonda. A restrição (8) garante que uma sonda, em um tempo específico, inicie no máximo uma intervenção. A restrição (9) limita o início das intervenções nos poços dentro da janela de tempo. A restrição (10) assegura que a conclusão da intervenção em cada poço ocorra apenas uma vez por uma sonda. A restrição (11) garante que uma sonda, em um tempo específico, conclua no máximo uma intervenção. A restrição (12) limita a conclusão das intervenções nos poços dentro da janela de tempo. A restrição (13) assegura que o período transcorrido entre o início e o fim da intervenção em cada poço seja exatamente o tempo de intervenção. A restrição (14) assegura que cada poço seja atendido sem interrupção dentro do início e fim estabelecidos para a intervenção. A restrição (15) garante que uma sonda, em um tempo específico, execute no máximo uma intervenção. A restrição (16) define o domínio das variáveis de decisão.

Nesta formulação, a variável  $C_{int}$  depende de  $S_{int}$  e a variável  $X_{int}$  depende de  $S_{int}$  e  $C_{int}$  para ser determinado. Note que a restrição (13) pode ser substituída na restrição (14):

$$X_{int} = \sum_{h=1}^t S_{inh} - \sum_{h=1}^{t-1} S_{in,h-d_i+1} \quad \forall i, n, t \quad (17)$$

Esta restrição pode ainda ser simplificada da seguinte forma:

$$X_{int} = \sum_{h=t-d_i+1}^t S_{inh} \quad \forall i, n, t \quad (18)$$

Observe que a equação (18) é equivalente à equação (14).

A equação (14) junto com a equação (15) garantem que não exista interferência entre o atendimento dos poços alocados em uma sonda. Agora, substituindo a equação (18) na equação (15), tem-se:

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq 1 \quad \forall n, t \quad (19)$$

Finalmente, o modelo matemático anterior pode ser reformulado substituindo as variáveis  $C_{int}$  e  $X_{int}$  como função da variável  $S_{int}$ , de modo que as restrições (10), (11) e (12) são desnecessárias. O Modelo Matemático Reformulado (MMR) é mostrado a seguir:

$$\text{(MMR) Min } \sum_{i=1}^J \sum_{n=1}^N \sum_{t=1}^T (t + d_i - a_i) p_i S_{int} \quad (20)$$

Sujeito a:

$$\sum_{n=1}^N \sum_{t=1}^T S_{int} = 1 \quad \forall i \quad (21)$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq 1 \quad \forall n, t \quad (22)$$

$$S_{int} \in \{0,1\} \quad \forall i, n, t \mid a_i \leq t \leq b_i - d_i + 1 \quad (23)$$

Neste modelo matemático, a função objetivo (20) representa a minimização da perda total de produção. A restrição (21) assegura que o início da intervenção em cada poço ocorra apenas uma vez por uma sonda. A restrição (22) cumpre a função das restrições (3) e (4) do MMO, isto é, que uma sonda, em um tempo específico, inicie no máximo uma intervenção e assegura que não exista interferência entre os serviços nos poços que utilizam a mesma sonda. A restrição (23) define o domínio das variáveis de decisão e assegura que o início das intervenções nos poços seja dentro da janela de tempo.

A partir do MMR é proposto o MMD, o qual é formulado com uma nova variável binária  $SD_{it}$ , que representa se a execução do serviço do poço  $i$  inicia no tempo  $t$ . A variável de decisão  $SD_{it}$  é determinada como segue:

$$SD_{it} = \sum_{n=1}^N S_{int} \quad \forall i, t \quad (24)$$

A variável  $SD_{it}$  poderia ser usada para substituir a variável  $S_{int}$  diretamente no MMR exceto na restrição (22). Agora, aplicando o somatório para  $\forall n$  na restrição (22), uma vez que é presumido que as sondas são homogêneas, tem-se:

$$\sum_{n=1}^N \sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq \sum_{n=1}^N 1 \quad \forall t \quad (25)$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t SD_{ih} \leq N \quad \forall t \quad (26)$$

Dado que no máximo  $N$  sondas executam os serviços de forma paralela nos poços; a restrição (26) garante que em um tempo específico sejam executados no máximo  $N$  intervenções, além de garantir que não exista interferência entre poços.

Substituindo a variável  $S_{int}$  em função da variável  $SD_{it}$  no MMR, obtém-se o MMD que determina o tempo de início ótimo das intervenções nos poços. O MMD é mostrado a seguir:

$$(MMD) \text{ Min } \sum_{i=1}^J \sum_{t=1}^T (t + d_i - a_i) p_i SD_{it} \quad (27)$$

Sujeito a:

$$\sum_{t=1}^T SD_{it} = 1 \quad \forall i \quad (28)$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t SD_{ih} \leq N \quad \forall t \quad (29)$$

$$SD_{it} \in \{0,1\} \quad \forall i, t | a_i \leq t \leq b_i - d_i + 1 \quad (30)$$

Neste modelo matemático, a função objetivo (27) representa a minimização da perda total de produção. A restrição (28) assegura que o início da intervenção

de cada poço ocorra apenas uma vez por uma sonda. A restrição (29) assegura que em um tempo específico, inicie no máximo  $N$  intervenções e que não exista interferência entre os serviços nos poços. A restrição (30) define o domínio das variáveis de decisão e assegura que o início das intervenções nos poços seja dentro da janela de tempo.

A partir do MMD são obtidas as soluções ótimas  $SD_{it}^*$ . Estas soluções serão utilizadas para determinar a alocação dos poços nas sondas. Esta alocação pode ser obtida mediante a construção de um algoritmo simples que aloque os poços nas sondas consecutivamente seguindo a ordem de atendimento no tempo. Outra forma de encontrar esta alocação é resolver o MMR, porém, redefinindo o domínio da variável  $S_{int}$  em função das soluções ótimas  $SD_{it}^*$ . A adequação do MMR para este fim é mostrada a seguir:

$$(MMR') \text{ Min } \sum_{i=1}^J \sum_{n=1}^N \sum_{t=1}^T (t + d_i - a_i) p_i S_{int} \quad (31)$$

Sujeito a:

$$\sum_{n=1}^N \sum_{t=1}^T S_{int} = 1 \quad \forall i \quad (32)$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq 1 \quad \forall n, t \quad (33)$$

$$S_{int} \in \{0,1\} \quad \forall i, n, t | SD_{it}^* = 1 \quad (34)$$

Neste modelo matemático, as restrições (32), (33) e a função objetivo (31) têm a mesma interpretação que as restrições (21), (22) e a função objetivo (20) do MMR respectivamente. A restrição (34) define o domínio restrito da variável  $S_{int}$ , assegurando que o tempo de início das intervenções nos poços sejam os valores encontrados de  $SD_{it}^*$ .

### 3.2.3 Comparação entre o MMO e o MMD

A Tabela 1 mostra o número total de restrições e variáveis utilizadas no MMO e no MMD.

Tabela 1 – Comparação do número de restrições e número de variáveis do MMO e MMD

MMO		MMD	
Eq.	Nº restrições	Eq.	Nº restrições
(2)	$J$	(28)	$J$
(3)	$N \times T$	(29)	$T$
(4)	$(J - 1) \times N \times \left( \sum_{i=1}^J \sum_{t=a_i}^{b_i-d_i+1} \sum_{h=t}^{t+d_i-1} 1 \right)$		
Eq.	Nº variáveis	Eq.	Nº variáveis
(5)	$N \times \left( \sum_{i=1}^J \sum_{t=a_i}^{b_i-d_i+1} 1 \right)$	(30)	$\sum_{i=1}^J \sum_{t=a_i}^{b_i-d_i+1} 1$

Pode-se observar que o MMD é formulado com um menor número de restrições em comparação do MMO, sendo que a restrição (4) desta última é a geradora da maior quantidade de restrições. Note que, enquanto o MMO utiliza as variáveis  $S_{imt}$  e  $S_{jmh}$  nas restrições (3) e (4), o MMD poupa o índice  $j$  da formulação e utiliza a variável  $SD_{ih}$  na restrição (29), isto é, utiliza uma quantidade menor de restrições. Observe que o número de variáveis é menor no MMD, já que o MMD não considera diretamente o problema de alocação de poços nas sondas.

Uma comparação numérica do crescimento de variáveis e restrições foi realizada na Tabela 2.

### 3.3 Experimentos computacionais

O desempenho do MMD foi testado em dois grupos de instâncias disponíveis na literatura. Para os experimentos, foi utilizado o AIMMS 3.14 com o solver CPLEX 12.6 e um computador de sistema operacional Windows 7 64 bits, o qual está equipado com um processador Intel Core i7-3960X 3,3 GHz e 64 GB de memória RAM.

### 3.3.1 Grupo de Instâncias N.1

Inicialmente o MMD foi comparado com o MMO, usando um grupo de instâncias propostas por Costa (2005) e que foram geradas a partir de casos reais no Brasil. Este grupo consiste em 25 instâncias que possuem 25, 50, 75, 100 e 125 poços com 2, 4, 6, 8 e 10 sondas. As instâncias com 25 e 50 poços são consideradas instâncias de pequeno porte; as instâncias com 75 poços são consideradas de médio porte; e as instâncias com 100 e 125 poços são consideradas de grande porte. Recentemente todos os resultados ótimos do Grupo de Instâncias N.1 foram publicados em Pérez et al. (2016) como parte do desenvolvimento desta tese de doutorado.

A seguir uma análise preliminar será realizada na Tabela 2, onde são mostrados o horizonte de tempo ( $T$ ), o número de variáveis, o número de restrições e os valores ótimos da função objetivo obtidos via relaxação linear do MMO e o MMD.

Tabela 2 – Resultados da relaxação linear aplicado ao MMO e MMD

Inst.	$T$	N° variáveis		N° restrições		Relaxação linear	
		MMO	MMD	MMO	MMD	MMO	MMD
25-2	60	2.832	1.416	289.297	85	10.608	16.329
25-4	30	2.664	666	264.529	55	8.232	10.312
25-6	20	2.496	416	239.761	45	7.571	8.497
25-8	20	3.328	416	319.673	45	7.217	7.733
25-10	20	4.160	416	399.585	45	7.054	7.322
50-2	120	11.832	5.916	2.480.670	170	29.130	66.904
50-4	80	15.324	3.831	3.244.170	130	21.608	37.891
50-6	40	10.986	1.831	2.290.550	90	19.196	28.346
50-8	30	10.648	1.331	2.195.490	80	17.996	23.788
50-10	30	13.310	1.331	2.744.350	80	17.342	21.348
75-2	180	26.484	13.242	8.640.675	255	75.123	187.236
75-4	90	25.968	6.492	8.409.795	165	53.279	103.199
75-6	60	25.452	4.242	8.178.915	135	46.069	75.498
75-8	50	27.936	3.492	8.933.755	125	42.576	61.881
75-10	40	27.420	2.742	8.702.875	115	40.475	53.876
100-2	240	47.286	23.643	21.279.640	340	96.416	299.040
100-4	120	46.572	11.643	20.842.060	220	65.433	159.939
100-6	90	51.858	8.643	23.119.120	190	55.115	114.264
100-8	70	53.144	6.643	23.586.420	170	50.142	91.746
100-10	60	56.430	5.643	24.958.600	160	47.189	78.364
125-2	280	69.158	34.579	37.268.637	405	122.173	380.505,5
125-4	150	73.316	18.329	39.330.549	275	77.919	200.291
125-6	100	72.474	12.079	38.684.261	225	63.182	140.493
125-8	80	76.632	9.579	40.746.173	205	55.915	110.774,3
125-10	60	70.790	7.079	37.391.685	185	51.561	93.040

Observa-se na Tabela 2 que o número de variáveis e restrições do MMO são maiores em relação ao MMD, sendo significativa a diferença do número de restrições do MMO e MMD. Além disso, de acordo com os valores da relaxação linear, o MMD obteve melhores limites inferiores para as distintas instâncias, com uma diferença em média de 40% com o MMO. Tal indício serve de suporte para a afirmação que a formulação do MMD (considerando a restrição (29) em lugar das restrições (3) e (4) do MMO) é mais forte no que se refere ao uso de métodos que se baseiam em relaxação linear (tal qual métodos baseados em estratégias *Branch-and-Bound*), que por sua vez implicam na obtenção de soluções ótimas de maneira mais eficiente.

Na Tabela 3 são apresentados os resultados obtidos da função objetivo pelos métodos exatos MMO e MMD e outros métodos disponíveis na literatura. Nesta

tabela encontram-se os métodos que obtiveram os melhores resultados para o grupo de instâncias de Costa (2005): *Genetic Algorithm* (GA) proposto por Douro e Lorenzoni (2009); *Memetic Algorithm* (MA) proposto por Pacheco (2011); e *Simulated Annealing* (SA) proposto por Ribeiro et al. (2011). Para o MMO e MMD foram estabelecidos como critérios de parada do solver o *gap* padrão ( $10^{-13}$ ) e o tempo limite de execução de 300s para resolver o problema.

Tabela 3 – Resultados computacionais dos diferentes métodos empregados no Grupo de Instâncias N.1

Inst.	Métodos exatos		Metaheurísticas		
	MMO	MMD	GA	MA	SA
25-2	<b>16.329</b>	<b>16.329</b>	<b>16.329</b>	<b>16.329</b>	<b>16.329</b>
25-4	<b>10.312</b>	<b>10.312</b>	<b>10.312</b>	<b>10.312</b>	<b>10.312</b>
25-6	<b>8.497</b>	<b>8.497</b>	8.499	<b>8.497</b>	<b>8.497</b>
25-8	<b>7.733</b>	<b>7.733</b>	7.736	<b>7.733</b>	<b>7.733</b>
25-10	<b>7.322</b>	<b>7.322</b>	7.325	<b>7.322</b>	<b>7.322</b>
50-2	<b>66.904</b>	<b>66.904</b>	66.907	<b>66.904</b>	<b>66.904</b>
50-4	<b>37.891</b>	<b>37.891</b>	37.896	<b>37.891</b>	<b>37.891</b>
50-6	<b>28.346</b>	<b>28.346</b>	28.353	<b>28.346</b>	<b>28.346</b>
50-8	<b>23.788</b>	<b>23.788</b>	<b>23.788</b>	<b>23.788</b>	<b>23.788</b>
50-10	<b>21.348</b>	<b>21.348</b>	21.351	<b>21.348</b>	<b>21.348</b>
75-2	<b>187.236</b>	<b>187.236</b>	187.240	<b>187.236</b>	<b>187.236</b>
75-4	<b>103.199</b>	<b>103.199</b>	103.218	103.204	103.202
75-6	<b>75.498</b>	<b>75.498</b>	75.524	75.499	75.499
75-8	<b>61.881</b>	<b>61.881</b>	61.916	61.884	61.882
75-10	<b>53.876</b>	<b>53.876</b>	53.889	53.881	<b>53.876</b>
100-2	-	<b>299.040</b>	299.051	299.041	299.041
100-4	-	<b>159.939</b>	159.983	159.945	159.948
100-6	-	<b>114.264</b>	114.275	114.273	114.274
100-8	-	<b>91.746</b>	91.769	91.765	91.758
100-10	-	<b>78.364</b>	78.402	78.391	78.376
125-2	-	<b>380.506</b>	380.523	380.511	380.511
125-4	-	<b>200.291</b>	200.368	200.297	200.302
125-6	-	<b>140.493</b>	140.550	140.513	140.503
125-8	-	<b>110.775</b>	110.844	110.782	110.787
125-10	-	<b>93.040</b>	93.078	93.049	93.045

Na Tabela 3, os valores marcados em negrito indicam as soluções ótimas encontradas pelos métodos exatos e pelas metaheurísticas. Observa-se que o MMO só foi capaz de resolver 15 instâncias dentro do tempo de execução estabelecido e sem conseguir um limite inferior para as instâncias restantes. Em contraste com o MMD, que foi capaz de encontrar as soluções ótimas para as 25

instâncias. Cabe ressaltar que as soluções ótimas das 15 últimas instâncias com 75, 100 e 125 poços (consideradas instâncias de médio e grande porte), eram desconhecidas na literatura até então e apenas as instâncias com 25 e 50 poços foram reportadas com otimalidade por Pacheco et al. (2009). Como foi usado um computador mais moderno que em Pacheco et al. (2009), foi possível achar soluções usando o MMO para as instâncias com 75 poços.

Com relação às metaheurísticas, em geral os melhores resultados foram obtidos pelo SA. Porém ele foi capaz de resolver apenas duas das instâncias de médio porte até a otimalidade. Note que para as instâncias de grande porte, os valores ótimos do MMD e os valores obtidos pelas metaheurísticas MA e SA são próximos entre si.

A Tabela 4 apresenta os tempos computacionais dos métodos exatos MMO e MMD (incluindo o tempo do MMR'), e os tempos computacionais reportados pelas metaheurísticas GA, MA e SA. Com a finalidade de realizar uma comparação equitativa, os tempos das metaheurísticas foram ajustados em proporção da velocidade dos computadores reportados por estas e o computador usado nesta tese. O computador Intel Core i7-3960X usado nos experimentos computacionais possui uma velocidade estimada de 129,43 GFLOPS. Estes dados estão disponíveis na lista de itens do site de TECHGAGE<sup>1</sup>, ACTIVEWIN<sup>2</sup> e NOTEBOOKCHECK<sup>3</sup>. Esta maneira de comparar os tempos computacionais foi proposta por Silva et al. (2012).

---

<sup>1</sup> Website: <http://techgage.com/>

<sup>2</sup> Website: <http://www.activewin.com/awin/default.asp>

<sup>3</sup> Website: <http://www.notebookcheck.net/>

Tabela 4 – Tempos computacionais (s) dos diferentes métodos empregados no Grupo de Instâncias N.1

Inst.	Métodos exatos		Metaheurísticas		
	MMO	MMD	GA <sup>4</sup>	MA <sup>5</sup>	SA <sup>6</sup>
25-2	3,3	0,0	0,1	0,4	0,1
25-4	3,0	0,0	0,1	0,6	0,1
25-6	3,1	0,0	0,0	0,6	0,2
25-8	4,3	0,0	0,0	0,8	0,2
25-10	5,4	0,0	0,0	1,1	0,2
50-2	30,2	0,3	0,3	0,6	0,2
50-4	36,1	0,2	0,3	1,1	0,2
50-6	26,0	0,0	0,1	1,2	0,2
50-8	25,9	0,0	0,3	1,7	0,2
50-10	32,6	0,0	0,2	2,2	0,3
75-2	122,7	1,4	0,7	0,9	0,3
75-4	105,1	0,4	0,5	1,2	0,2
75-6	98,2	0,2	0,5	2,0	0,3
75-8	111,2	0,1	0,3	2,7	0,3
75-10	112,5	0,1	0,5	3,6	0,3
100-2	-	3,8	1,1	2,8	0,3
100-4	-	1,5	0,9	1,6	0,3
100-6	-	0,5	2,6	2,4	0,3
100-8	-	0,5	2,7	3,3	0,4
100-10	-	0,3	1,1	4,5	0,4
125-2	-	6,2	2,8	1,7	0,4
125-4	-	3,3	1,1	1,9	0,3
125-6	-	0,9	1,6	3,1	0,4
125-8	-	0,8	1,2	4,1	0,4
125-10	-	0,5	3,1	5,5	0,4
Média	48,0	0,8	0,9	2,1	0,3
Desvio	45,4	1,5	0,9	1,3	0,1

Comparando o MMO e o MMD na Tabela 4, o MMD mostrou que pode resolver o problema de maneira mais eficiente. Por exemplo, nas instâncias com 75 poços o MMO precisou de 109,9s em média (considerando as 5 instâncias de 75 poços), enquanto o MMD precisou de 0,4s em média, isto é, uma redução de 99,6% do tempo consumido. Nas instâncias com 25 e 50 poços, o MMD também apresentou uma redução notável do tempo consumido. Nas instâncias de grande porte com 100 e 125 poços, o MMD precisou de 1,3s e 2,3s em média

<sup>4</sup> Computador: Pentium IV 2.0 GHz de processador com 480 MB de memória RAM (Velocidade: 2,44 GFLOPS)

<sup>5</sup> Computador: Intel Core i3 330M 2.13 GHz de processador com 4GB de memória RAM (Velocidade: 20,48 GFLOPS)

<sup>6</sup> Computador: AMD Athlon 64 3500 2.2 GHz de processador com 1 GB de memória RAM (Velocidade: 3,62 GFLOPS)

respectivamente. O MMD apresentou um tempo computacional não superior a 7s para resolver cada instância e precisando de 0,8s em média.

Observa-se na Tabela 4 que o desvio padrão do tempo de execução do MMD é maior que das metaheurísticas; e que o tempo médio de execução do MMD é menor que do GA e do MA, e maior que do SA. Porém, sob o ponto de vista do tempo computacional, o MMD pode ser considerado tão competitivo como as metaheurísticas, tendo como justificativa que estas só conseguiram valores próximos ao ótimo para as instâncias de grande porte, e que em geral, as metaheurísticas devem realizar várias replicações para garantir a robustez da solução encontrada, além do tempo dispensado com experimentos prévios necessários para o ajuste dos parâmetros de execução.

### **3.3.2 Grupo de Instâncias N.2**

O MMD será utilizado para resolver um grupo de instâncias geradas por Neves (2007). Estas instâncias consistem em 50, 100 e 500 poços com 5 e 10 sondas, que se encontram distribuídos em um campo terrestre de petróleo com suas respectivas coordenadas cartesianas. Cada quantidade de poços contém 10 instâncias diferentes. Para este experimento não são considerados os tempos de transporte das sondas entre os poços.

A Tabela 5 apresenta os valores ótimos da função objetivo (FO) e o tempo de execução do MMD (incluindo o tempo do MMR<sup>^</sup>) nas instâncias de acordo ao horizonte de tempo. Foi estabelecido como critério de parada do solver o *gap* padrão ( $10^{-13}$ ) para resolver o problema.

Tabela 5 – Resultados computacionais do MMD no Grupo de Instâncias N.2

Instâncias	FO	Tempo (s)	Instâncias	FO	Tempo (s)
Horizonte = 80			Horizonte = 50		
50-5/1	7.263	0,4	50-10/1	4.149	0,1
50-5/2	7.378	0,3	50-10/2	4.221	0,3
50-5/3	5.484	0,3	50-10/3	3.154	0,2
50-5/4	5.294	0,3	50-10/4	3.028	0,2
50-5/5	7.692	0,3	50-10/5	4.389	0,2
50-5/6	6.501	0,3	50-10/6	3.708	0,3
50-5/7	7.341	0,4	50-10/7	4.179	0,2
50-5/8	6.033	0,3	50-10/8	3.450	0,3
50-5/9	7.800	0,4	50-10/9	4.441	0,2
50-5/10	6.877	0,3	50-10/10	3.951	0,1
Horizonte = 140			Horizonte = 80		
100-5/1	31.036	2,0	100-10/1	16.638	0,7
100-5/2	25.886	1,7	100-10/2	13.918	1,0
100-5/3	24.373	1,9	100-10/3	13.101	0,7
100-5/4	22.021	1,8	100-10/4	11.863	0,8
100-5/5	26.872	1,9	100-10/5	14.421	0,7
100-5/6	24.569	2,0	100-10/6	13.202	0,8
100-5/7	29.621	2,1	100-10/7	15.887	0,8
100-5/8	26.816	1,7	100-10/8	14.394	0,7
100-5/9	25.766	2,0	100-10/9	13.835	0,9
100-5/10	24.625	1,6	100-10/10	13.243	0,8
Horizonte = 640			Horizonte = 330		
500-5/1	612.342	835,3	500-10/1	310.850	162,2
500-5/2	595.739	967,2	500-10/2	302.418	122,1
500-5/3	612.903	720,1	500-10/3	311.095	126,2
500-5/4	631.968	761,2	500-10/4	320.747	110,5
500-5/5	629.462	827,2	500-10/5	319.486	111,7
500-5/6	581.665	816,1	500-10/6	295.279	114,8
500-5/7	595.679	1.038,7	500-10/7	302.368	154,6
500-5/8	608.089	743,4	500-10/8	308.667	163,4
500-5/9	618.348	811,8	500-10/9	313.902	157,9
500-5/10	619.043	977,3	500-10/10	314.248	167,6

Os resultados da Tabela 5 mostram que todas as instâncias foram resolvidas de maneira ótima. As instâncias com 50 e 100 poços tomaram um tempo reduzido de execução, a diferença das instâncias de grande porte de 500 poços que levaram vários minutos, isto devido ao crescimento exponencial do espaço de soluções. As instâncias de pequeno porte de 50 poços com 5 sondas precisaram 0,3s em média e com 10 sondas precisaram 0,2s em média para serem resolvidas. As instâncias de grande porte de 100 poços com 5 sondas precisaram 1,9s em média e com 10 sondas precisaram 0,8s em média. As instâncias de grande porte de 500 poços com 5 sondas precisaram 14,2 min em média e com 10 sondas precisaram 2,3 min em média.

Note que, quando é considerado um número menor de sondas, é preciso um horizonte de tempo maior para atender todos os poços, o que provoca um aumento

no número de variáveis e restrições, e portanto, um incremento no tempo de execução. Por exemplo, nas instâncias de 500 poços com 5 sondas, o horizonte considerado é de 640 unidades de tempo e com 10 sondas, o horizonte é de 330 unidades de tempo, sendo o primeiro caso que precisa de maior esforço computacional.

No próximo capítulo é apresentado o segundo modelo matemático proposto. Este modelo é uma extensão do MMD descrito neste capítulo, considerando sondas heterogêneas e procurando determinar o itinerário de atendimento dos poços, junto com o dimensionamento da frota de sondas.

## 4

### **Problema de otimização de itinerário e dimensionamento de frota de sondas para poços terrestres de petróleo**

Este problema é uma extensão do Problema de Otimização de Itinerário de Sondas para poços terrestres de petróleo e se aproxima mais a um contexto real de operação, considerando os custos da perda de produção de petróleo e os custos de aluguel de sondas ou alocação de sondas em uma região dentro de um prazo estipulado para o atendimento dos poços. Neste contexto, um conjunto de sondas pode não ser suficiente para atender a demanda dos poços, podendo haver a necessidade de novas sondas. Assim, o problema confronta a redução do custo da perda produção com o aumento do custo de utilização de sondas.

Em comparação com o problema apresentado no Capítulo 3, o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas para poços terrestres de petróleo é menos abordado na literatura.

Borchardt (2002) apresentou uma formulação matemática e desenvolveu um *Proto-Gene Algorithm* (PGA) com busca local e um *Hybrid Genetic Algorithm* (HGA). Aloise et al. (2002) aplicaram um *Ant Colony Optimization* (ACO). Gouvêa et al. (2002) desenvolveram um *Memetic Algorithm* (MA) e um PGA para o problema. Estes trabalhos utilizaram instâncias aleatórias nos experimentos computacionais.

Irgens et al. (2008) aplicaram um algoritmo de busca local, considerando na formulação minimizar a perda de produção, incluindo nas restrições a condição que o custo do uso das sondas não ultrapasse o orçamento designado. Sabry (2012) e Sabry et al. (2012) apresentaram uma formulação matemática, uma metaheurística *Greedy Randomized Adaptive Search Procedure* (GRASP) e um MA.

Os trabalhos mais relevantes tratando o problema foram apresentados por Bissoli (2014) e Bissoli et al. (2014). Os autores incorporaram o custo de aluguel de sondas na modelagem matemática proposta por Ribeiro, Desaulniers e Desrosiers (2012) e implementaram uma metaheurística *Adaptive Large Neighborhood Search* (ALNS). Vários experimentos computacionais foram

realizados, variando o preço do petróleo, o horizonte de tempo e o custo horário das sondas, verificando o impacto no tamanho da frota de sondas.

A seguir é descrito o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas para poços terrestres de petróleo, apresentado o segundo modelo matemático proposto. Nos experimentos computacionais, o modelo proposto foi testado em novas instâncias geradas aleatoriamente.

#### 4.1 Descrição do problema

O problema apresentado neste capítulo é caracterizado por considerar um conjunto de poços  $i = 1, \dots, J$  que requerem um determinado nível de serviço  $r_i$  e uma frota heterogênea de sondas  $n = 1, \dots, N$ , as quais podem executar diversos níveis de serviços de manutenção  $v_n$ . As sondas são agrupadas por classe  $m = 1, \dots, M$ , cada classe  $m$  possui um número de sondas disponíveis  $M_m$ , um nível de serviço  $w_m$  e um custo horário da classe de sonda  $\beta_m$ . O nível de serviço da sonda  $v_n$  é derivado do nível de serviço  $w_m$  de uma dada classe de sonda. Cada poço  $i$  está associado a um tempo de intervenção  $d_i$  e um valor de vazão de petróleo  $p_i$ . Um poço pode apenas ser atendido por sondas com níveis de serviço maiores ou iguais ao nível de serviço requerido pelo poço.

Um exemplo da relação entre o nível de serviço das sondas e o nível de serviço requerido dos poços é mostrado na Figura 4. Suponha um campo com 10 poços, 3 classes de sondas e duas sondas por classe. Na figura as sondas de classe 3 têm a capacidade de atender qualquer poço, as sondas de classe 2 têm a capacidade de atender os poços {1,2,3,4,6,7,9,10} e as sondas de classe 1 têm a capacidade de atender os poços {3,6,9,10}. As sondas de níveis menores são restritas e atendem um subconjunto dos poços.

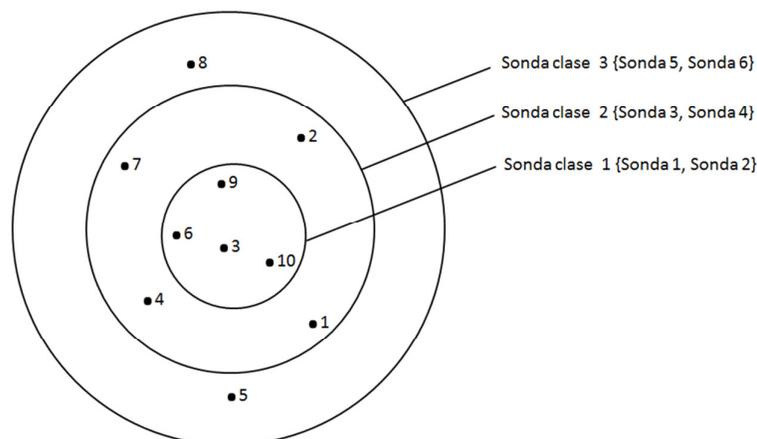


Figura 4 – Exemplo da representação do nível de serviço das sondas e dos poços  
 Fonte: Adaptado de Soares et al. (2011, p.2207)

Neste contexto, os poços podem ou não ser selecionados para receber a intervenção dentro do horizonte de tempo  $T$ . Dessa forma, o Problema de Otimização de Itinerário e Dimensionamento Frota de Sondas (POIDFS) para poços terrestres de petróleo consiste em determinar o tamanho da frota de sondas e o itinerário destas para atender aos poços com o objetivo de minimizar o custo da perda de produção de petróleo e o custo de uso das sondas em um horizonte de tempo. O custo de perda de produção é contabilizado de acordo ao preço de petróleo estabelecido  $\alpha$  e à perda de produção dos poços.

As hipóteses consideradas são semelhantes às do Capítulo 3, exceto que a frota de sondas é considerada heterogênea.

## 4.2 Formulação do problema

Na Seção 3.3 foi verificada a eficiência do MMD para resolver o Problema de Otimização de Itinerário de Sondas para poços terrestres de petróleo em comparação com o MMO e as metaheurísticas propostas na literatura. Assim, nesta seção é apresentada uma extensão do MMD para formular o POIDFS. A notação usada dos índices, parâmetros e variáveis de decisão é definida a seguir:

## Índices

$i$ : Índice de poços,  $i = \{1, 2, \dots, J\}$

$n$ : Índice de sondas disponíveis,  $n = \{1, 2, \dots, N\}$

$m$ : Índice de classe de sonda,  $m = \{1, 2, \dots, M\}$

$t, h$ : Índice de tempo,  $t, h = \{1, 2, \dots, T\}$

## Parâmetros

$J$ : Número de poços

$N$ : Número de sondas disponíveis

$M$ : Número de classes de sonda

$M_m$ : Número de sondas por classe  $m$

$T$ : Horizonte de tempo

$p_i$ : Vazão de petróleo do poço  $i$

$d_i$ : Duração da intervenção no poço  $i$

$r_i$ : Nível de serviço requerido do poço  $i$

$v_n$ : Nível de serviço da sonda  $n$

$w_m$ : Nível de serviço da classe de sonda  $m$

$\beta_m$ : Custo horário da classe de sonda  $m$

$\alpha$ : Preço do petróleo

## Variáveis

$S_{int} = \begin{cases} 1, & \text{se a sonda } n \text{ inicia a execução do serviço do poço } i \text{ no tempo } t \\ 0, & \text{caso contrário} \end{cases}$

$SD_{imt} = \begin{cases} 1, & \text{se a sonda de classe } m \text{ inicia a execução do serviço do poço } i \\ & \text{no tempo } t \\ 0, & \text{caso contrário} \end{cases}$

$SA_n = \begin{cases} 1, & \text{se a sonda } n \text{ for alugada} \\ 0, & \text{caso contrário} \end{cases}$

$SU_m$ : Número de sondas utilizadas de classe  $m$

Inicialmente, uma extensão do MMR descrito na Seção 3.2.2 é formulada considerando a variável  $S_{int}$ , a variável binária  $SA_n$  e uma variável inteira  $SU_m$ . A variável  $SA_n$  indica se uma sonda  $n$  for alugada e a variável  $SU_m$  representa o número de sondas utilizadas de classe  $m$ .

A extensão do MMR para o POIDFS é apresentada a seguir:

$$\begin{aligned} \text{(MMR) Min } & \left( \sum_{i=1}^J \sum_{n=1}^N \sum_{t=1}^T (t + d_i - 1) p_i S_{int} + T \sum_{i=1}^J p_i \left( 1 - \sum_{n=1}^N \sum_{t=1}^T S_{int} \right) \right) \alpha \\ & + T \sum_{m=1}^M SU_m \beta_m \end{aligned} \quad (35)$$

Sujeito a:

$$\sum_{n=1}^N \sum_{t=1}^T S_{int} \leq 1 \quad \forall i \quad (36)$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq SA_n \quad \forall t, n \quad (37)$$

$$\sum_{n=1|v_n=w_m}^N SA_n = SU_m \quad \forall m \quad (38)$$

$$SU_m \leq M_m \quad \forall m \quad (39)$$

$$S_{int} \in \{0,1\} \quad \forall i, n, t | 1 \leq t \leq T - d_i + 1 \text{ e } r_i \leq v_n \quad (40)$$

$$SA_n \in \{0,1\} \quad \forall n \quad (41)$$

$$SU_m \in \mathbb{Z}^+ \quad \forall m \quad (42)$$

Neste modelo matemático, a função objetivo (35) representa a minimização do custo da perda de produção e o custo de utilização das sondas no horizonte de tempo. O primeiro componente da perda de produção corresponde à perda dos poços selecionados e o segundo componente corresponde à perda dos poços não selecionados. Note que a perda de produção dos poços não selecionados ocorre durante todo o horizonte de tempo. A restrição (36) assegura que o início da intervenção em cada poço ocorra no máximo uma vez por uma sonda. A restrição (37) assegura que as sondas alugadas realizem no máximo uma intervenção e que não exista interferência entre os serviços nos poços. A restrição (38) determina o número de sondas alugadas por classe, isto é, as sondas que tenham um nível de serviço  $v_n$  iguais ao nível de serviço  $w_m$  da classe de sonda  $m$  serão agrupadas. A restrição (39) garante que o número de sondas utilizadas por classe seja no máximo o número de sondas disponíveis por classe. As restrições (40), (41) e (42) definem o domínio das variáveis de decisão. A restrição (40) assegura que o início

das intervenções nos poços seja dentro do horizonte de tempo e que cada poço seja servido por uma de sonda com o nível de serviço apropriado.

A extensão do MMD é formulada com uma nova variável binária  $SD_{imt}$ , que representa se a sonda de classe  $m$  inicia a execução do serviço do poço  $i$  no tempo  $t$ . A variável de decisão  $SD_{imt}$  é determinada como segue:

$$SD_{imt} = \sum_{n=1|v_n=w_m}^N S_{int} \quad \forall i, m, t \quad (43)$$

A equação (43) serve para identificar a classe de sonda atribuída a um poço. Esta equação procura a classe de sonda atribuída ao poço, tal que os níveis de serviço da sonda atribuída e da classe de sonda sejam iguais ( $v_n = w_m$ ).

A variável  $SD_{imt}$  pode ser usada para substituir a variável  $S_{int}$  no MMR com a finalidade de reduzir o número de variáveis e restrições utilizadas, já que geralmente o número de classes de sondas é menor que o número de sondas disponíveis ( $M < N$ ).

Uma vez que é presumido que as sondas da mesma classe  $m$  desempenham um nível de serviço  $w_m$ , pode ser aplicado um somatório  $\forall n|v_n = w_m$  na restrição (37):

$$\sum_{n=1|v_n=w_m}^N \sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq \sum_{n=1|v_n=w_m}^N SA_n \quad \forall t, m \quad (44)$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t SD_{imh} \leq SU_m \quad \forall t, m \quad (45)$$

Dado que no máximo  $SU_m$  sondas por classe  $m$  executam os serviços de forma paralela nos poços alocados, a restrição (45) garante que em um tempo específico sejam executados no máximo  $SU_m$  intervenções por classe de sonda  $m$ , além de garantir que não exista interferência entre poços.

Substituindo a variável  $S_{int}$  em função da variável  $SD_{imt}$  no MMR, obtém-se um MMD que determina o tempo de início ótimo das intervenções, assim como a classe de sonda alocada para cada poço. O MMD é mostrado a seguir:

$$\begin{aligned}
\text{(MMD) Min } & \left( \sum_{i=1}^J \sum_{m=1}^M \sum_{t=1}^T (t + d_i - 1) p_i SD_{imt} + T \sum_{i=1}^J p_i \left( 1 - \sum_{m=1}^M \sum_{t=1}^T SD_{imt} \right) \right) \alpha \\
& + T \sum_{m=1}^M SU_m \beta_m
\end{aligned} \tag{46}$$

Sujeito a:

$$\sum_{m=1}^M \sum_{t=1}^T SD_{imt} \leq 1 \quad \forall i \tag{47}$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t SD_{imh} \leq SU_m \quad \forall t, m \tag{48}$$

$$SU_m \leq M_m \quad \forall m \tag{49}$$

$$SD_{imt} \in \{0,1\} \quad \forall i, m, t | 1 \leq t \leq T - d_i + 1 \text{ e } r_i \leq w_m \tag{50}$$

$$SU_m \in \mathbb{Z}^+ \quad \forall m \tag{51}$$

Neste modelo matemático, a função objetivo (46) representa a minimização do custo da perda de produção e o custo de utilização das sondas no horizonte de tempo. O primeiro componente da perda de produção corresponde à perda dos poços selecionados e o segundo componente corresponde à perda dos poços não selecionados dentro do horizonte de tempo. A restrição (47) assegura que o início da intervenção em cada poço ocorra no máximo uma vez por uma classe de sonda. A restrição (48) assegura que em um tempo específico, cada classe de sonda inicie no máximo  $SU_m$  intervenções e que não exista interferência entre os serviços nos poços. A restrição (49) garante que o número de sondas utilizadas por classe seja no máximo o número de sondas disponíveis por classe. As restrições (50) e (51) definem o domínio das variáveis de decisão. A restrição (50) assegura que o início das intervenções nos poços seja dentro do horizonte de tempo e que cada poço seja servido por uma de classe de sonda com o nível de serviço apropriado.

A partir do MMD são obtidas as soluções ótimas do  $SD_{imt}^*$  e  $SU_m^*$ . Assim como explicado na Seção 3.2.2, para determinar a alocação dos poços nas sondas alugadas, deve-se resolver a extensão do MMR, redefinindo o domínio da variável  $S_{int}$  em função das soluções ótimas  $SD_{imt}^*$  e a restrição que relaciona a variável  $SA_n$  com as soluções ótimas  $SU_m^*$ . A adequação do MMR para este fim é mostrada a seguir:

$$\begin{aligned}
(\text{MMR}') \text{ Min } & \left( \sum_{i=1}^J \sum_{n=1}^N \sum_{t=1}^T (t + d_i - 1) p_i S_{int} + T \sum_{i=1}^J p_i (1 - \sum_{n=1}^N \sum_{t=1}^T S_{int}) \right) \alpha \\
& + T \sum_{m=1}^M SU_m^* \beta_m
\end{aligned} \tag{52}$$

Sujeito a:

$$\sum_{n=1}^N \sum_{t=1}^T S_{int} \leq 1 \quad \forall i \tag{53}$$

$$\sum_{i=1}^J \sum_{h=t-d_i+1}^t S_{inh} \leq SA_n \quad \forall t, n \tag{54}$$

$$\sum_{n=1|v_n=w_m}^N SA_n = SU_m^* \quad \forall m \tag{55}$$

$$S_{int} \in \{0,1\} \quad \forall i, n, t \quad \sum_{m=1|v_n=w_m}^M SD_{imt}^* = 1 \tag{56}$$

$$SA_n \in \{0,1\} \quad \forall n \tag{57}$$

Neste modelo matemático, a função objetivo (52) representa a minimização do custo da perda de produção e o custo de aluguel das sondas no horizonte de tempo. O primeiro componente da perda de produção corresponde à perda dos poços selecionados e o segundo componente corresponde à perda dos poços não selecionados dentro do horizonte de tempo. A restrição (53) assegura que o início da intervenção de cada poço ocorra no máximo uma vez por uma sonda. A restrição (54) assegura que as sondas utilizadas realizem no máximo uma intervenção e que não exista interferência entre os serviços nos poços. A restrição (55) garante que o total de sondas utilizadas por classe seja exatamente os valores encontrados de  $SU_m^*$ . As restrições (56) e (57) definem o domínio das variáveis de decisão. A restrição (56) restringe a variável  $S_{int}$ , assegurando que o início das intervenções e a alocação nas sondas por classe sejam os valores encontrados em  $SD_{imt}^*$ .

### 4.3 Experimentos computacionais

Para avaliar o desempenho do MMD para resolver o POIDFS, foram gerados 6 grupos de instâncias de médio e grande porte a partir das instâncias de Costa (2005) e outros trabalhos relacionados, onde cada grupo consiste em 5 instâncias com 75, 100, 125, 150, 175 e 200 poços.

No Apêndice encontram-se os detalhes dos dados para o problema. Para o grupo de instâncias com 75 e 100 poços foram atribuídas 4 sondas disponíveis por classe e para o grupo de instâncias com 125, 150, 175 e 200 poços foram atribuídas 5 sondas disponíveis por classe. O horizonte de tempo foi estabelecido em 15 e 30 dias. O preço do petróleo ( $\alpha$ ) é suposto em US\$ 250/m<sup>3</sup> (aproximadamente US\$ 40/bbl) e US\$ 350/m<sup>3</sup> (aproximadamente US\$ 55/bbl).

O MMD foi implementado no AIMMS 3.14, usando o solver CPLEX 12.6 e executado em um computador de sistema operacional Windows 7 64 bits, o qual está equipado com um processador Intel Core i7-3960X 3,3 GHz e 64 GB de memória RAM. Foi estabelecido como critério de parada do solver o *gap* padrão ( $10^{-13}$ ) para resolver o problema.

As Tabelas 6 e 7 apresentam os resultados computacionais do MMD variando o preço do petróleo e o horizonte de tempo para cada grupo de instâncias, onde são mostrados o número de sondas alugadas da classe 3 (C3), classe 4 (C4) e classe 5 (C5); o número de poços atendidos (Atend); a porcentagem do custo das sondas em relação ao custo total (%CS); e o tempo computacional (Tp) para resolver cada instância (incluindo o tempo do MMR).

Tabela 6 – Resultados computacionais do MMD com  $\alpha = \text{US\$ } 250/\text{m}^3$ 

Inst.	Horizonte = 15 dias						Horizonte = 30 dias					
	Sondas utilizadas			Atend	% CS	Tp (s)	Sondas utilizadas			Atend	% CS	Tp (s)
	C3	C4	C5				C3	C4	C5			
75/1	3	0	2	40	33	0,9	3	1	1	68	45	9,4
75/2	2	1	2	42	32	1,0	3	0	2	66	44	2,4
75/3	4	1	1	41	35	0,5	3	1	1	66	43	2,9
75/4	4	0	2	45	40	0,6	3	0	1	57	36	3,0
75/5	4	1	1	46	37	0,3	3	1	1	70	45	7,7
100/1	4	2	1	58	32	0,9	4	1	1	83	39	2,0
100/2	4	2	1	58	33	0,6	4	1	1	86	40	2,5
100/3	4	2	2	62	33	1,0	4	1	1	83	34	3,2
100/4	4	1	2	56	30	0,8	4	1	1	83	36	3,5
100/5	4	1	2	60	32	1,3	4	1	1	88	38	2,5
125/1	5	3	4	89	39	1,0	4	2	3	121	43	17,0
125/2	5	4	1	77	28	2,2	5	2	2	118	39	18,0
125/3	5	3	2	83	32	1,1	5	2	2	122	43	3,7
125/4	5	3	1	81	31	2,3	5	2	1	119	40	16,7
125/5	5	4	2	90	38	2,6	5	2	1	116	39	3,2
150/1	5	5	1	88	34	1,5	5	3	1	136	40	3,5
150/2	5	4	2	90	33	0,9	5	2	2	129	39	17,4
150/3	5	4	1	80	30	1,5	5	3	1	127	38	4,1
150/4	5	3	2	82	32	1,8	5	2	2	130	41	18,0
150/5	5	5	3	102	36	1,6	5	3	2	143	40	12,5
175/1	5	5	2	101	32	1,3	5	4	2	158	42	13,0
175/2	5	5	1	87	26	0,8	5	5	1	151	38	5,2
175/3	5	5	2	102	30	1,0	5	4	2	164	41	16,7
175/4	5	5	3	103	29	1,9	5	5	2	167	40	11,5
175/5	5	5	4	112	31	1,6	5	4	3	160	39	3,5
200/1	5	5	5	111	30	1,0	5	5	3	176	37	14,5
200/2	5	5	2	99	27	2,5	5	5	2	175	39	6,9
200/3	5	5	3	111	31	1,0	5	5	2	178	40	5,8
200/4	5	5	3	101	28	1,5	5	5	3	179	41	7,9
200/5	5	5	2	100	26	1,2	5	5	2	172	39	14,2

Tabela 7 – Resultados computacionais do MMD com  $\alpha = \text{US\$ } 350/\text{m}^3$ 

Inst.	Horizonte = 15 dias						Horizonte = 30 dias					
	Sondas utilizadas			Atend	% CS	Tp (s)	Sondas utilizadas			Atend	% CS	Tp (s)
	C3	C4	C5				C3	C4	C5			
75/1	4	1	2	53	36	0,9	3	1	1	68	37	2,3
75/2	4	1	2	55	34	0,6	3	1	2	73	44	2,4
75/3	4	2	1	47	33	0,5	4	1	1	72	41	6,1
75/4	4	0	2	46	32	0,6	4	0	2	71	46	2,7
75/5	4	2	1	53	35	0,0	4	1	1	74	44	1,7
100/1	4	4	1	70	33	1,4	4	2	1	93	37	3,6
100/2	4	4	1	68	35	1,2	4	2	1	95	39	1,9
100/3	4	4	2	72	33	0,7	4	2	2	97	39	4,6
100/4	4	2	2	63	27	1,4	4	2	2	100	41	3,6
100/5	4	3	2	74	33	1,5	4	1	2	95	38	9,5
125/1	5	4	5	101	37	1,3	5	2	3	124	38	7,8
125/2	5	5	2	89	28	1,0	5	3	2	122	36	4,6
125/3	5	4	3	95	31	1,4	5	2	2	122	35	7,2
125/4	5	4	2	94	32	1,7	5	2	2	124	39	14,4
125/5	5	5	2	95	33	0,6	5	3	2	124	41	5,6
150/1	5	5	2	99	31	0,7	5	4	1	141	37	5,5
150/2	5	5	2	98	29	1,8	5	4	2	146	39	2,3
150/3	5	5	2	95	30	1,9	5	4	2	143	40	5,4
150/4	5	5	3	105	34	1,9	5	3	2	140	38	4,5
150/5	5	5	4	111	32	4,9	5	5	2	148	39	16,3
175/1	5	5	4	115	31	1,5	5	5	2	164	38	4,3
175/2	5	5	5	106	30	1,7	5	5	2	159	35	8,5
175/3	5	5	5	124	31	1,0	5	5	2	168	36	7,0
175/4	5	5	5	117	28	1,2	5	5	3	173	36	4,9
175/5	5	5	5	117	27	1,4	5	5	4	173	38	3,9
200/1	5	5	5	111	23	1,9	5	5	5	190	36	4,6
200/2	5	5	5	121	28	1,1	5	5	3	185	35	19,9
200/3	5	5	5	126	29	0,6	5	5	4	195	40	17,9
200/4	5	5	5	114	26	0,7	5	5	4	186	37	9,2
200/5	5	5	5	123	27	1,7	5	5	3	180	35	16,4

Nas Tabelas 6 e 7 observa-se que o MMD foi capaz de resolver todas as instâncias em um curto tempo computacional, precisando de 4,9s e 4,2s em média respectivamente (considerando todas as instâncias de cada tabela).

Os resultados mostram, por exemplo, com um horizonte de 15 dias, considerando um preço do petróleo de  $250/\text{m}^3$  são atendidos 59% dos poços em média, e considerando um preço do petróleo de  $350/\text{m}^3$  a porcentagem de poços atendidos aumenta para 68% em média. Quando o horizonte é de 30 dias com um

preço do petróleo de  $250/m^3$ , os poços atendidos são 89% em média e aumentando para 96% em média com um preço do petróleo de  $350/m^3$ .

Igualmente quando o horizonte de tempo aumenta de 15 dias para 30 dias, a porcentagem do custo das sondas aumenta de 31% para 39% em média respectivamente. Isto indica que, o tamanho ótimo da frota de sondas é dado antes do ponto de equilíbrio (custo da perda de produção igual ao custo de utilização das sondas).

A análise indica que um aumento no preço do barril provoca um aumento no número de poços atendidos e influencia (i.e. torna mais vantajoso) para aumentar o tamanho da frota de sondas. Além disso, um aumento no horizonte de tempo provoca um aumento no número de poços atendidos e uma diminuição, na maioria dos casos, do número de sondas utilizadas.

No próximo capítulo é apresentado o terceiro modelo matemático proposto, o qual considera a incerteza presente no tempo de intervenção. Este modelo de programação estocástica é uma extensão MMD descrito neste capítulo.

## 5

### **Problema de otimização de itinerário e dimensionamento de frota de sondas sob incerteza para poços terrestres de petróleo**

Costa (2005), Duhamel et al. (2012) e Monemi et al. (2015) alertam que uma das grandes dificuldades no planejamento de itinerário de sondas é a incerteza presente na determinação do tempo de intervenção e que neste processo o bom senso do programador é de extrema importância para se atribuir valores com precisão. Desta forma, com a finalidade de reduzir os erros no planejamento e antecipar eventos inesperados que possam atrasar as intervenções ou prolongar o tempo estimado destas, nesta tese foi abordado o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas sob incerteza para poços terrestres de petróleo, considerando o tempo de intervenção incerto.

Accioly e Chiyoshi (1998) foram os primeiros em considerar incerteza neste problema. Os autores propuseram um modelo de simulação para serviços manutenção de bombas centrífugas submersas de poços marítimos, com o objetivo de obter a relação entre o número de sondas usadas e a perda de produção esperada. Os experimentos de Accioly e Chiyoshi (1998) foram baseados em dados reais da Bacia de Campos localizada na costa do Estado do Rio de Janeiro, considerando valores determinísticos para a vazão de petróleo e definindo a distribuição de falhas das bombas e a distribuição dos tempos de intervenção.

Costa (2005) apresentou um tratamento estatístico dos parâmetros de vazão de petróleo e do tempo de intervenção, usando uma série histórica de intervenções de casos reais da bacia de São Mateus, no norte do Espírito Santo. O autor construiu curvas de probabilidade para estes parâmetros, com o objetivo de desenhar experimentos determinísticos para o Problema de Otimização de Itinerário de Sondas para poços terrestres de petróleo. Igualmente, Aloise et al. (2006) apresentaram os valores médios e máximos do tempo de intervenção, do tempo de transporte entre poços pela sonda e da vazão de petróleo para casos reais da bacia de Potiguar localizada na região nordeste do Brasil.

Bassi (2010) e Bassi et al. (2012) apresentaram o primeiro enfoque estocástico para o problema em poços marítimos, no qual são considerados

aspectos operacionais, tais como: a lâmina de água, a profundidade dos poços, as coordenadas geográficas dos poços, a profundidade que pode atingir a sonda, a presença de  $H_2S$ , o índice de produtividade da sonda, a velocidade de transporte da sonda e as coordenadas geográficas das sondas. Os autores realizaram experimentos computacionais baseados em dados reais das Bacias de Espírito Santo, Campos e Santos no Brasil, estabelecendo o tempo de intervenção como incerto. Um método de simulação-otimização foi desenvolvido para determinar o valor esperado da perda de produção, as medidas de desempenho das sondas e estatísticas sobre alocação de poços nas sondas. A fase de simulação consiste em variar o tamanho da frota de sondas e realizar a geração de cenários do parâmetro incerto pelo método *Monte Carlo*. A fase de otimização consiste em resolver o problema com cada cenário gerado, utilizando para este fim um algoritmo guloso e a metaheurística *Greedy Randomized Adaptive Search Procedure*. O tamanho da frota de sondas é determinado analisando o *tradeoff* entre o custo de aluguel das sondas e o custo esperado da perda de produção.

Nesta tese, é desenvolvido um novo enfoque para abordar o Problema de Otimização de Dimensionamento de Frota de Sondas sob incerteza para poços terrestres de petróleo. Um modelo de programação estocástica de dois estágios é formulado, sendo definidos três métodos de geração de cenários para representar a incerteza do tempo de intervenção. Além disso, é avaliada a estabilidade dos métodos de geração de cenários com a finalidade de estabelecer a melhor opção entre estes métodos e determinar o número de cenários adequados para resolver o problema com precisão.

## 5.1 Modelo de programação estocástica de dois estágios

Um problema otimização estocástica é definido como (Linderoth et al., 2006):

$$\min_{x \in X} \{F(x, \xi) := \mathbb{E}[f(x, \xi)]\}$$

Onde  $X$  é um subconjunto de  $\mathbb{R}^n$  e  $\xi$  é um vetor aleatório em  $\mathbb{R}^m$ . Aqui o problema consiste em minimizar o valor esperado de  $f(x, \xi)$  de acordo com a distribuição de probabilidade de  $\xi$ .

Geralmente, problemas de otimização estocástica são reduzidos a modelos de programação estocástica de dois estágios, da forma:

$$\min_{x \in X} \{F(x, \xi) := c^T x + \mathbb{E}[Q(x, \xi)]\}$$

onde

$$Q(x, \xi) := \min\{q^T y : Ay \geq H - Bx, y \geq 0\}$$

é o valor ótimo do segundo estágio e  $\xi := (q, A, B, H)$  denota os parâmetros que podem ser aleatórios. No modelo de programação estocástica de dois estágios, a variável  $x$  constitui o primeiro estágio, o qual conforma as decisões que precisam ser tomadas antes da realização da incerteza  $\xi$ . A variável  $y$  constitui a decisões tomadas após uma determinada decisão de primeiro estágio e uma realização da incerteza  $\xi$ . Usualmente  $\mathbb{E}[Q(x, \xi)]$  é difícil de ser avaliada exatamente.

Em particular, o modelo de programação estocástica de dois estágios apresenta duas fontes de dificuldade quando é formulado com variáveis inteiras (Ahmed & Shapiro, 2002):

1. A avaliação exata do valor esperado do segundo estágio. Para uma dada decisão de primeiro estágio e uma realização dos dados aleatórios, o segundo estágio é resolvido via programação inteira. Assim, para várias distribuições de probabilidade contínuas do parâmetro incerto, a avaliação exata do valor esperado do segundo estágio envolve o cálculo de uma integral multidimensional do valor objetivo da função  $Q(x, \xi)$ , o qual é impossível em termos práticos. Para distribuições de probabilidade discretas, o valor esperado requer resolver todas as possíveis realizações do parâmetro incerto, podendo ser computacionalmente intratável.
2. A otimização do valor esperado do segundo estágio. Mesmo se o valor esperado puder ser avaliado ou aproximado, o problema estocástico envolve otimizar  $\mathbb{E}[Q(x, \xi)]$  sobre as decisões de primeiro estágio. É sabido que funções de modelos de programação inteira são não convexas e descontínuas. Consequentemente, a otimização do problema traz dificuldades computacionais graves.

Em tais condições, não é prático resolver um problema de otimização estocástica diretamente. No entanto, podem-se utilizar técnicas de amostragem que consideram um subconjunto aleatório de  $\xi$  para obtenção de resultados aproximados.

Suponha que uma amostra aleatória independente  $\xi^k$ ,  $k = 1, \dots, K$  (chamado de cenários) é gerada a partir de uma distribuição  $\xi$ . A aproximação do problema de otimização estocástica com base nessa amostra é dada por (Shapiro & Homem-de-Mello, 1998):

$$\min_{x \in X} \{F(x, \xi^k) := \frac{1}{K} \sum_{k=1}^K f(x, \xi^k)\}$$

A função  $F(x, \xi^k)$  é o estimador da função de objetivo  $F(x, \xi)$  utilizando os cenários  $\xi^1, \dots, \xi^K$ , onde cada cenário possui a mesma probabilidade de ocorrência  $1/K$ . Esta aproximação da função objetivo é conhecida como *Sample Average Approximation* (SAA).

## 5.2 Métodos de geração de cenários

Diversas técnicas de amostragens (geração de cenários) podem ser utilizadas para o problema de otimização estocástica. A seguir é apresentada uma breve descrição de alguns métodos de geração de cenários disponíveis na literatura.

### 5.2.1 Método *Monte Carlo*

O método *Monte Carlo* é o enfoque mais comum para tratar problemas de otimização estocástica. O método consiste em gerar uma sequência pseudo-aleatória (que imita aleatoriedade) de números independentes e uniformemente distribuídos no intervalo [0-1], para depois construir uma amostra mediante uma apropriada transformação da distribuição de probabilidade. O algoritmo mais conhecido para geração de números pseudo-aleatórios é o Gerador de Congruência Linear. A taxa de convergência associada ao método *Monte Carlo* é de  $O(1/\sqrt{K})$ , isto é, a velocidade com que o erro do estimador diminui com o aumento do tamanho da amostra  $K$  (Glasserman, 2003).

A Figura 5 mostra um exemplo de uma amostra gerada com 1000 cenários pelo método *Monte Carlo*.

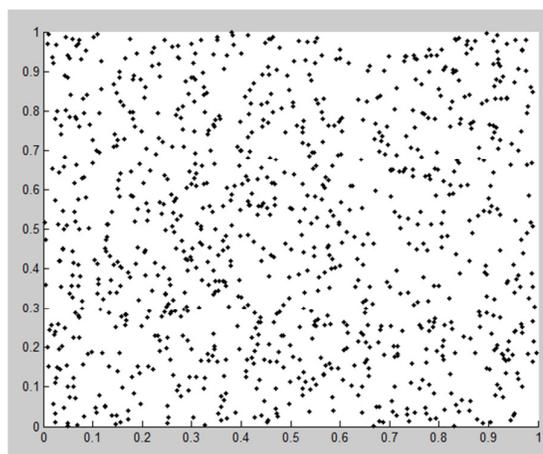


Figura 5 – Exemplo de uma amostra bidimensional *Monte Carlo*

### 5.2.2 Método de Redução de Cenários

O método de Redução de Cenários foi desenvolvido inicialmente por Dupacová et. al (2003) e por Heitsch e Römisch (2003, 2007), consistindo em encontrar um subconjunto de cenários que se aproxima a um conjunto inicial de cenários de acordo a uma métrica de distância probabilística. Neste processo são atribuídas novas probabilidades aos cenários preservados e probabilidade zero aos cenários removidos. A métrica mais utilizada é a *Fortet-Mourier*. A Figura 6 mostra um exemplo do método de Redução de Cenários a partir de uma amostra de 1000 cenários e ressaltando o subconjunto de 8 cenários representativos.

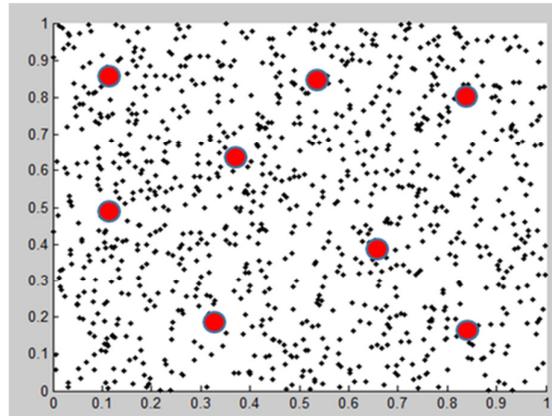


Figura 6 – Exemplo do método de Redução de Cenários de uma amostra bidimensional

O método de Redução de Cenários é comumente usado em problemas de otimização estocástica que consideram um número elevado de cenários e requerem tempos muito longos de execução. Para problemas com variáveis aleatórias de dimensão elevada, a desvantagem do método é o aumento do erro entre a distribuição aproximada e a distribuição inicial, produzindo valores subótimos da função objetivo (Löhndorf, 2016).

### 5.2.3 Método *Quasi-Monte Carlo*

O método *Quasi-Monte Carlo* gera amostras chamadas de sequências de baixa discrepância ou números quasi-aleatórios, que visam aumentar a precisão do estimador gerando pontos altamente uniformes.

As sequências de baixa discrepância preenchem espaços de forma uniforme no intervalo [0-1] até uma densidade específica e tem o potencial de acelerar a taxa de convergência de  $O(1/\sqrt{K})$  associada com o *Monte Carlo* a uma taxa aproximada de  $O(1/K)$ . Geralmente o método *Quasi-Monte Carlo* tem sido caracterizado como apropriado para problemas com variáveis aleatórias de dimensão elevada. A sequência mais utilizada é a *Sobol sequence*, por ser mais efetiva e produz resultados precisos em diversos problemas (Glasserman, 2003).

A Figura 7 mostra um exemplo de uma amostra de 1000 cenários utilizando a sequência de *Sobol*.

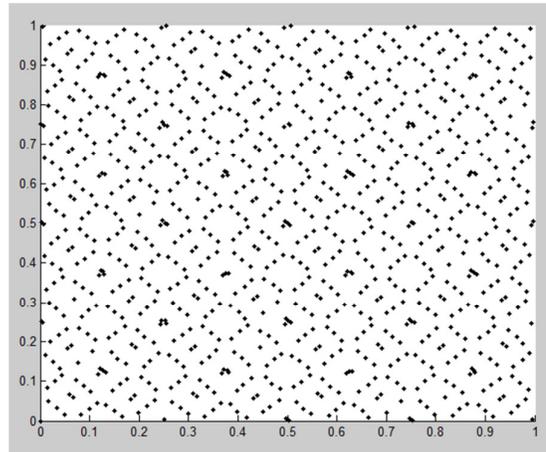


Figura 7 – Exemplo de uma amostra bidimensional *Quasi-Monte Carlo*

### 5.3 Avaliação do método de geração de cenários

Kaut e Wallace (2003) propuseram os testes de estabilidade *in-sample* e *out-of-sample* para avaliar a qualidade do método de geração de cenários de um problema de otimização estocástica.

Os testes de estabilidade são amplamente usados em diversas áreas de pesquisa. Por exemplo, na área de finanças (Kaut et al., 2007; Beraldi & Bruni, 2014; Beraldi et al., 2014; Davari-Ardakani et al., 2016), na área geração de energia (Faria & Fleten, 2011; Fleten et al., 2011; Vespucci et al., 2012; Seljom & Tomsgard, 2015; Vojvodic et al., 2016), na área de transporte (Maggioni et al., 2009; Perboli et al., 2015; Mørch et al., 2017) e na área gestão de suprimento de petróleo (Oliveira et al., 2016).

Os testes de estabilidade são baseados na SAA e utilizados para determinar o número de cenários necessários para resolver um problema de otimização estocástica com precisão. A seguir são definidos os testes de estabilidade *in-sample* e *out-of-sample*:

#### 5.3.1 Teste de estabilidade *In-sample*

Se para resolver um modelo de programação estocástica são realizadas  $L$  replicações de uma amostra independente  $\xi_l$ ,  $l = 1, \dots, L$  com  $K$  cenários gerados

a partir de uma distribuição de probabilidade de um parâmetro incerto  $\xi$ , dessa forma, a estabilidade *in-sample* verifica se os valores da função objetivo são próximos ou iguais em cada replicação, isto é:

$$F(x_l^*, \xi_l) \approx F(x_{l'}^*, \xi_{l'}) \quad l, l' \in 1 \dots L$$

Onde  $x_l^*$  é a solução ótima de primeiro estágio da replicação  $l$ .

### 5.3.2

#### Teste de estabilidade *Out-of-sample*

A estabilidade *out-of-sample* verifica se as soluções ótimas de primeiro estágio  $x_l^*$  obtidas em cada replicação  $l$ , produzem valores próximos ou iguais na função objetivo quando avaliadas com a distribuição verdadeira do parâmetro incerto  $\xi$ , isto é:

$$F(x_l^*, \xi) \approx F(x_{l'}^*, \xi) \quad l, l' \in 1 \dots L$$

Note que em geral não é possível avaliar a função objetivo com a distribuição verdadeira, pois é necessário conhecer por completo a distribuição ou disponibilizar de dados históricos. Para tais casos, uma opção é definir um conjunto de cenários de referência o suficientemente grande tal que se aproxime à distribuição verdadeira.

## 5.4

### Descrição do problema

O Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas sob incerteza para poços terrestres de petróleo é uma extensão do problema descrito no Capítulo 4. A principal diferença é a incerteza presente no tempo de intervenção nos poços. Aqui, cada poço  $i$  está associado a um conjunto de cenários do tempo de intervenção  $d_i^k$ ,  $k = 1, \dots, K$ . Dessa forma, o problema consiste em determinar o tamanho da frota de sondas para atender aos poços, de modo que o custo de utilização das sondas e o custo esperado da perda de produção dentro de um horizonte de tempo sejam minimizados. O objetivo do problema é dar apoio na tomada de decisão, reduzindo o efeito na perda de produção devido a eventos inesperados.

## 5.5 Formulação do problema

O problema é formulado como um modelo de programação estocástica de dois estágios, onde a incerteza do tempo de intervenção é discretizada com base a uma amostra aleatória (cenários) com certa probabilidade de ocorrência  $\pi_k$  para cada cenário  $k$ . A variável de primeiro estágio é o tamanho da frota de sondas ( $SU_m$ ) e a variável de segundo estágio corresponde ao início da intervenção de uma classe de sonda nos poços em um determinado cenário ( $SD_{imt}^k$ ). A notação usada para os índices, parâmetros e variáveis de decisão é definida a seguir:

### Índices

$i$ : Índice de poços,  $i = \{1, 2, \dots, J\}$

$m$ : Índice de classe de sonda,  $m = \{1, 2, \dots, M\}$

$t, h$ : Índice de tempo,  $t, h = \{1, 2, \dots, T\}$

$k$ : Índice de cenários,  $k = \{1, 2, \dots, K\}$

### Parâmetros determinísticos

$J$ : Número de poços

$M$ : Número de classes de sonda

$M_m$ : Número de sondas por classe  $m$

$T$ : Horizonte de tempo

$K$ : Número de cenários gerados

$p_i$ : Vazão de petróleo do poço  $i$

$r_i$ : Nível de serviço requerido do poço  $i$

$w_m$ : Nível de serviço da classe de sonda  $m$

$\beta_m$ : Custo horário da classe de sonda  $m$

$\alpha$ : Preço do petróleo

### Parâmetros estocásticos

$d_i^k$ : Duração da intervenção no poço  $i$  no cenário  $k$

$\pi_k$ : Probabilidade de ocorrência do cenário  $k$

### Variável de primeiro estágio

$SU_m$ : Número de sondas utilizadas da classe  $m$

### Variável de segundo estágio

$$SD_{imt}^k = \begin{cases} 1, & \text{se a sonda de classe } m \text{ inicia a execução do serviço do poço } i \\ & \text{no tempo } t \text{ e no cenário } k \\ 0, & \text{caso contrário} \end{cases}$$

A extensão do MMD descrito na Seção 4.2 para o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas sob incerteza para poços terrestres de petróleo é mostrado a seguir:

$$\begin{aligned} \text{(MMD) Min } & \sum_{k=1}^K \left( \sum_{i=1}^J \sum_{m=1}^M \sum_{t=1}^T (t + d_i^k - 1) p_i SD_{imt}^k \right. \\ & \left. + T \sum_{i=1}^J p_i (1 - \sum_{m=1}^M \sum_{t=1}^T SD_{imt}^k) \right) \pi_k \alpha + T \sum_{m=1}^M SU_m \beta_m \end{aligned} \quad (58)$$

Sujeito a:

$$\sum_{m=1}^M \sum_{t=1}^T SD_{imt}^k \leq 1 \quad \forall i, k \quad (59)$$

$$SU_m \leq M_m \quad \forall m \quad (60)$$

$$\sum_{i=1}^J \sum_{h=t-d_i^k+1}^t SD_{imh}^k \leq SU_m \quad \forall m, t, k \quad (61)$$

$$SD_{imt}^k \in \{0,1\} \quad \forall i, m, t, k | 1 \leq t \leq T - d_i^k + 1 \text{ e } r_i \leq w_m \quad (62)$$

$$SU_m \in \mathbb{Z}^+ \quad \forall m \quad (63)$$

Neste modelo matemático, a função objetivo (58) representa a minimização do custo esperado da perda de produção e o custo de utilização das sondas no horizonte de tempo. O primeiro componente da perda de produção corresponde à perda dos poços selecionados e o segundo componente corresponde à perda dos poços não selecionados dentro do horizonte de tempo. A restrição (59) assegura que o início da intervenção em cada poço e em cada cenário ocorra no máximo uma vez por uma classe de sonda. A restrição (60) garante que o número de sondas utilizadas por classe seja no máximo o número de sondas disponíveis por

classe. A restrição (61) assegura que para cada cenário, em um tempo específico, cada classe de sonda inicie no máximo  $SU_m$  intervenções e que não exista interferência entre os serviços nos poços. As restrições (62) e (63) definem o domínio das variáveis de decisão.

## 5.6 Experimentos computacionais

Os experimentos computacionais foram realizados considerando três instâncias de grande porte. A geração de cenários do tempo de intervenção e os valores da vazão de petróleo são baseados nas curvas de probabilidade construídas por Costa (2005). Os parâmetros adicionais também se encontram descritos no Apêndice. O preço do petróleo é suposto em US\$ 250/m<sup>3</sup> e o horizonte de tempo é estabelecido em 15 dias.

Para a geração de cenários são usados os métodos de *Monte Carlo* (MC), Redução de Cenários (RC) e *Quasi-Monte Carlo* (QMC). Os métodos MC e QMC foram implementados em MATLAB R2013a, empregando para o QMC a sequência de baixa discrepância *Sobol* com a opção *scramble* para embaralhar esta sequência. Para o método de RC foi empregada a ferramenta SCENRED2 disponível no GAMS, e sendo configurada com a métrica *Fortet-Mourier*, o algoritmo de redução *Forward*, a norma euclidiana de ordem 1 e um conjunto inicial de 1.000 cenários. Os parâmetros da RC foram definidos com base a experimentos prévios, tomando em consideração o tempo necessário e a eficiência da redução.

Para realizar o teste de estabilidade *out-of-sample* foi gerado uma amostra aleatória com 10.000 cenários, a qual representará o conjunto de cenários de referência. Esta consideração é assumida, pois não há disponibilidade de dados quanto ao histórico de intervenções. Para realizar o teste de estabilidade *in-sample* foram geradas 30 replicações, as quais são avaliadas com diferentes números de cenários. As soluções de primeiro estágio obtidas nas replicações ( $x_i^*$ 's) são avaliadas no conjunto de cenários de referência para medir a estabilidade *out-of-sample*. A Figura 8 mostra a representação de um exemplo com 100 poços e 50 cenários para a aplicação dos testes *in-sample* e *out-of-sample*.

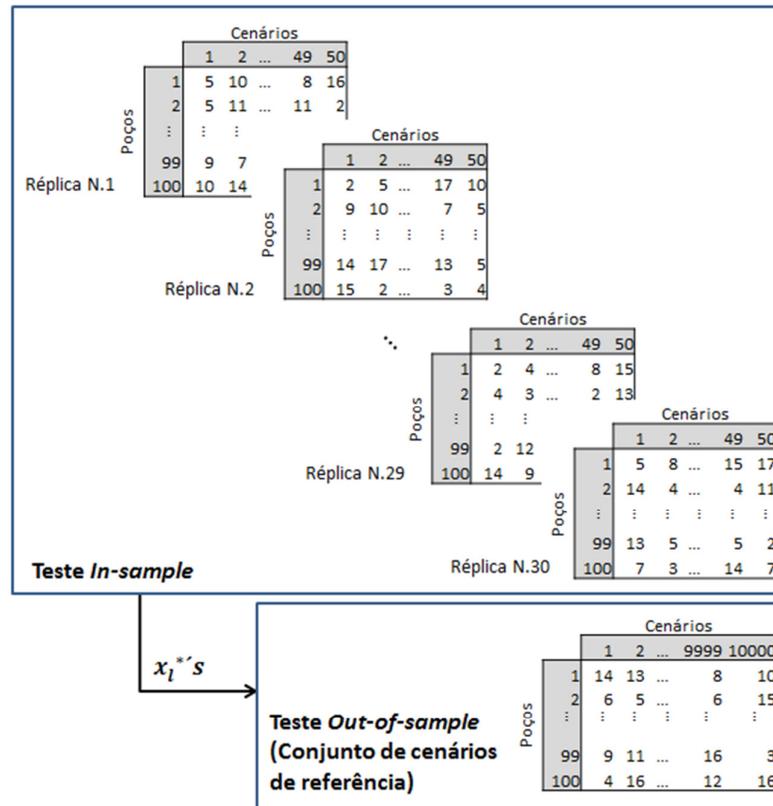


Figura 8 – Exemplo de geração de cenários para realizar os testes *in-sample* e *out-of-sample*

Para um número grande de cenários, o problema torna-se desafiador para a obtenção de soluções ótimas devido ao aumento no número de variáveis, restrições e recursos computacionais. Com a finalidade de obter soluções de primeiro estágio no teste *in-sample* que se aproximem à solução ótima de primeiro estágio “verdadeira”, a qual é obtida resolvendo o problema com o conjunto de cenários de referência, inicialmente uma análise preliminar é realizada com um número reduzido de cenários em cada replicação. As soluções de primeiro estágio encontradas na análise preliminar podem ser usadas para resolver o problema com otimalidade para um número maior de cenários no teste *in-sample*. Para isso, o MMD descrito na Seção 5.5 é utilizado, fixando a variável  $SU_m$  com cada uma destas soluções encontradas para reduzir o espaço de busca do problema. Esta metodologia será utilizada nos próximos experimentos.

Para a análise preliminar foi estabelecido como critério de parada do solver o *gap* de 0.01%. Tal definição se mostrou necessária devido ao tempo prolongado que o solver CPLEX apresentou para convergir do limite inferior ao valor ótimo,

mesmo quando o melhor valor encontrado era sabido ser o valor ótimo ou muito próximo dele, conforme verificado nas observações dos experimentos. Para avaliar o teste *in-sample* depois da análise preliminar e o teste *out-of-sample* foi estabelecido como critério de parada do solver o *gap* padrão ( $10^{-13}$ ).

A Figura 9 apresenta o esquema da metodologia aplicada para realizar os testes *in-sample* e *out-of-sample* nos experimentos computacionais.

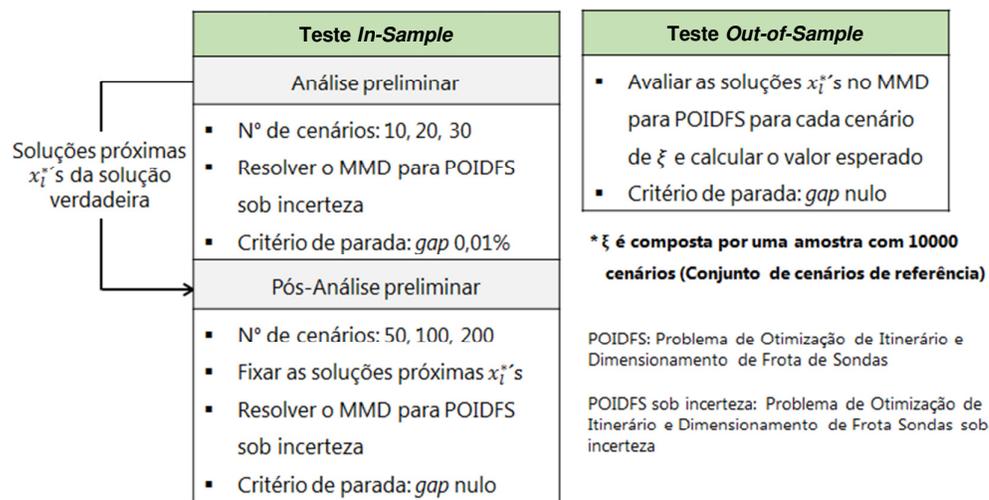


Figura 9 – Metodologia para realizar os testes *in-sample* e *out-of-sample*

O MMD para este problema foi implementado no AIMMS 3.14, usando o solver CPLEX 12.6 e executado em um computador de sistema operacional Windows 7 64 bits, o qual está equipado com um processador Intel Core i7-3960X 3,3 GHz e 64 GB de memória RAM.

### 5.6.1 Instância N.1

Para esta primeira instância foi considerado um problema com 100 poços e 4 sondas disponíveis por classe. Nesta instância, são avaliados os métodos de geração de cenários MC, RC e QMC para determinar o método de melhor desempenho para resolver o problema.

As Tabelas 8, 9 e 10 apresentam os resultados da análise preliminar considerando em cada replicação 10, 20 e 30 cenários respectivamente. As Tabelas 11, 12 e 13 apresentam os resultados considerando um número maior de

cenários em cada replicação com 50, 100 e 200 cenários respectivamente. Nestas tabelas são comparados os métodos de geração de cenários MC, RC e QMC. Na estabilidade *in-sample*, são apresentadas as soluções de primeiro estágio do número de sondas utilizadas da classe 3 (C3), classe 4 (C4) e classe 5 (C5), além da frequência nas replicações (Freq), o número de poços atendidos em média (Atend), o custo total médio (Custo) e o tempo de execução médio destas soluções (Tp). A estabilidade *out-of-sample* mostra o número de poços atendidos em média (Atend), o custo total médio (Custo) e o tempo de execução avaliando as soluções encontradas do teste *in-sample* (Tp).

Tabela 8 – Resultados computacionais da análise preliminar com 10 cenários da Instância N.1

Teste	<i>In-sample</i>							<i>Out-of-sample</i>		
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
Método	C3	C4	C5							
MC	4	3	1	3	63,3	1.664.235	16,6	63,7	1.666.183	3.843,3
	4	2	2	10	64,9	1.638.793	18,1	64,3	1.662.532	4.489,8
	4	3	2	17	70,4	1.674.771	18,6	70,4	1.662.322	4.536,3
Média					67,8	1.661.725	18,2	67,7	1.662.778	4.451,5
Desv.					3,1	25.943		3,1	1.139	
RC	4	3	1	1	64,3	1.606.448	16,9	63,7	1.666.183	3.843,3
	4	2	2	8	65,5	1.601.001	19,5	64,3	1.662.532	4.489,8
	4	3	2	21	71,7	1.621.847	17,0	70,4	1.662.322	4.536,3
Média					69,8	1.615.774	17,7	68,6	1.662.507	4.500,8
Desv.					3,0	19.184		2,8	689	
QMC	4	2	2	10	64,4	1.652.363	18,2	64,3	1.662.532	4.489,8
	4	3	2	20	70,1	1.673.393	17,5	70,4	1.662.322	4.536,3
Média					68,2	1.666.383	17,7	68,4	1.662.392	4.520,8
Desv.					2,7	14.411		2,9	99	

Observa-se na Tabela 8 que o QMC, no teste *in-sample* foram encontradas duas soluções de primeiro estágio nas 30 replicações. A primeira solução com 4 sondas C3, 2 sondas C4 e 2 sondas C5; e a segunda solução com 4 sondas C3, 3 sondas C4 e 2 sondas C5. A primeira solução possui uma frequência de 10 replicações e a segunda solução uma frequência de 20 replicações. Para estas soluções o número de poços atendidos em média é de 68,2 (com desvio de 2,7), o custo total esperado é de US\$ 1.666.383 (com desvio de US\$ 14.411) e o tempo de execução média para resolver a instância com 10 cenários simultaneamente é de 17,7s. Para estas soluções de primeiro estágio, o teste *out-of-sample* reporta

que o número de poços atendidos em média é de 68,4 (com desvio de 2,9), o custo total esperado é de US\$ 1.662.392 (com desvio de US\$ 99) e o tempo de execução média para avaliar a instância com o conjunto de cenários de referência é de 4.520,8s.

Na mesma Tabela 8, o MC e a RC, no teste *in-sample* foram encontradas três soluções de primeiro estágio nas 30 replicações. A primeira solução com 4 sondas C3, 3 sondas C4 e 1 sondas C5; a segunda e terceira solução também foram encontradas pelo QMC. A observação mais importante nesta tabela é a diferença entre os valores do desvio padrão do QMC com o MC e a RC nos testes *in-sample* e *out-of-sample*, sendo os desvios destes últimos consideravelmente maiores.

Tabela 9 – Resultados computacionais da análise preliminar com 20 cenários da Instância N.1

Teste	<i>In-sample</i>							<i>Out-of-sample</i>		
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
Método	C3	C4	C5							
MC	4	3	1	3	64,6	1.637.861	46,7	63,7	1.666.183	3.843,3
	4	2	2	12	64,4	1.652.950	51,5	64,3	1.662.532	4.489,8
	4	3	2	15	70,4	1.669.969	49,7	70,4	1.662.322	4.536,3
Média					67,4	1.659.951	50,1	67,3	1.662.792	4.448,4
Desv.					3,1	18.579		3,1	1.135	
RC	4	2	2	5	65,8	1.603.062	53,7	64,3	1.662.532	4.489,8
	4	3	2	25	71,5	1.623.183	49,5	70,4	1.662.322	4.536,3
Média					70,5	1.619.829	50,2	69,4	1.662.357	4.528,6
Desv.					2,3	15.102		2,3	78	
QMC	4	2	2	10	64,3	1.658.424	51,5	64,3	1.662.532	4.489,8
	4	3	2	20	70,5	1.662.005	50,7	70,4	1.662.322	4.536,3
Média					68,4	1.660.811	51,0	68,4	1.662.392	4.520,8
Desv.					2,9	5.733		2,9	99	

A Tabela 9 apresenta as mesmas soluções de primeiro estágio da Tabela 8. Observa-se no teste *in-sample* uma redução do desvio padrão no MC, na RC e no QMC, sendo deste último a mais significativa. No teste *out-of-sample* observa-se uma redução significativa do desvio padrão da RC, isto devido à desconsideração da solução com 4 sondas C3, 3 sondas C4 e 1 sondas C5. Tanto o MC, a RC e o QMC mostram que a instância considerando 20 cenários simultaneamente pode ser resolvida em 51s aproximadamente.

Tabela 10 – Resultados computacionais da análise preliminar com 30 cenários da Instância N.1

Teste	<i>In-sample</i>							<i>Out-of-sample</i>			
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)	
	C3	C4	C5								
MC	4	2	2	4	64,9	1.648.938	72,0	64,3	1.662.532	4.489,8	
	4	3	2	26	70,2	1.674.492	70,0	70,4	1.662.322	4.536,3	
Média					69,5	1.671.085	70,3	69,6	1.662.350	4.530,1	
Desv.					1,9	16.175		2,1	71		
RC	4	2	2	3	65,4	1.604.097	169,0	64,3	1.662.532	4.489,8	
	4	3	2	27	71,4	1.624.899	71,5	70,4	1.662.322	4.536,3	
Média					70,8	1.622.818	81,2	69,8	1.662.343	4.531,7	
Desv.					1,9	13.097		1,8	63		
QMC	4	2	2	9	64,4	1.660.959	102,2	64,3	1.662.532	4.489,8	
	4	3	2	21	70,4	1.662.516	81,7	70,4	1.662.322	4.536,3	
Média					68,6	1.662.049	87,9	68,6	1.662.385	4.522,4	
Desv.					2,8	3.679		2,8	96		

Na Tabela 10, o MC, a RC e o QMC encontraram as mesmas duas soluções de primeiro estágio. Note que estas soluções foram reportadas também nas Tabelas 8 e 9. Observa-se no teste *in-sample* outra redução do desvio padrão do MC, da RC e do QMC. No teste *out-of-sample* observa-se uma redução significativa do desvio padrão do MC, isto devido à desconsideração da solução com 4 sondas C3, 3 sondas C4 e 1 sondas C5. Esta a tabela mostra que a instância considerando 30 cenários simultaneamente pode ser resolvida entre 70s e 169s.

Agora, as Tabelas 8, 9 e 10 são utilizadas para realizar uma análise preliminar das soluções que se aproximam à solução ótima de primeiro estágio “verdadeira”. A clara tendência na redução do desvio padrão do MC, a RC e o QMC nos testes *in-sample* e *out-of-sample*, e as duas soluções repetidas nestas tabelas, sugerem tomar estas soluções como candidatas à solução ótima da Instância N.1. Desta forma, estas soluções serão usadas para reduzir o espaço de busca e a complexidade do problema, quando sejam considerados cenários maiores.

As duas soluções resultantes da análise preliminar, onde uma delas considera mais uma sonda C4, indicam que aumentar a frota de sondas pode ser vantajoso. Estas soluções serão analisadas nas Tabelas 11, 12 e 13, as quais consideram em cada replicação 50, 100 e 200 cenários respectivamente.

Tabela 11 – Resultados computacionais com 50 cenários da Instância N.1

Teste	<i>In-sample</i>							<i>Out-of-sample</i>		
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
	C3	C4	C5							
MC	4	2	2	7	64,5	1.652.600	45,6	64,3	1.662.532	4.489,8
	4	3	2	23	70,5	1.666.876	45,0	70,4	1.662.322	4.536,3
Média					69,1	1.663.545	45,2	69,0	1.662.371	4.525,5
Desv.					2,5	10.553		2,6	89	
RC	4	2	2	4	64,7	1.611.464	45,1	64,3	1.662.532	4.489,8
	4	3	2	26	70,7	1.627.437	44,6	70,4	1.662.322	4.536,3
Média					69,9	1.625.307	44,7	69,6	1.662.350	4.530,1
Desv.					2,1	11.594		2,1	71	
QMC	4	2	2	11	64,4	1.660.353	45,9	64,3	1.662.532	4.489,8
	4	3	2	19	70,5	1.662.014	44,6	70,4	1.662.322	4.536,3
Média					68,3	1.661.405	45,1	68,2	1.662.399	4.519,3
Desv.					2,9	2.507		2,9	101	

Tabela 12 – Resultados computacionais com 100 cenários da Instância N.1

Teste	<i>In-sample</i>							<i>Out-of-sample</i>		
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
	C3	C4	C5							
MC	4	2	2	12	64,4	1.655.541	90,6	64,3	1.662.532	4.489,8
	4	3	2	18	70,4	1.664.364	90,4	70,4	1.662.322	4.536,3
Média					68,0	1.660.835	90,5	68,0	1.662.406	4.517,7
Desv.					3,0	7.579		3,0	103	
RC	4	2	2	4	63,7	1.617.967	91,4	64,3	1.662.532	4.489,8
	4	3	2	26	69,9	1.631.946	90,6	70,4	1.662.322	4.536,3
Média					69,1	1.630.082	90,7	69,6	1.662.350	4.530,1
Desv.					2,1	10.312		2,1	71	
QMC	4	2	2	2	64,4	1.658.902	90,1	64,3	1.662.532	4.489,8
	4	3	2	28	70,4	1.662.274	91,4	70,4	1.662.322	4.536,3
Média					70,0	1.662.049	91,3	70,0	1.662.336	4.533,2
Desv.					1,5	1.351		1,5	52	

Tabela 13 – Resultados computacionais com 200 cenários da Instância N.1

Teste	<i>In-sample</i>							<i>Out-of-sample</i>		
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
Método	C3	C4	C5							
MC	4	2	2	14	64,4	1.657.138	180,9	64,3	1.662.532	4.489,8
	4	3	2	16	70,3	1.665.280	182,0	70,4	1.662.322	4.536,3
Média					67,6	1.661.481	181,5	67,6	1.662.420	4.514,6
Desv.					2,9	5.720		3,0	105	
RC	4	2	2	4	63,5	1.626.961	187,0	64,3	1.662.532	4.489,8
	4	3	2	26	69,7	1.638.115	183,0	70,4	1.662.322	4.536,3
Média					68,9	1.636.628	183,5	69,6	1.662.350	4.530,1
Desv.					2,1	8.878		2,1	71	
QMC	4	3	2	30	70,5	1.662.256	180,7	70,4	1.662.322	4.536,3
Média					70,5	1.662.256	180,7	70,4	1.662.322	4.536,3
Desv.					0,1	713		0,0	0	

Observa-se nas Tabelas 11, 12 e 13 que o MC e a RC mantiveram as duas soluções encontradas anteriormente. Em contraste, o QMC a partir de 100 cenários apresenta uma tendência por uma única solução. Esta decisão fica esclarecida nos resultados da Tabela 13, onde o QMC sugere vantajoso utilizar mais uma sonda C4 para cobrir a variabilidade do tempo de intervenção, atendendo 70,5 poços (com desvio 0,1) com um custo mínimo de US\$ 1.662.256 em média (com desvio US\$ 713) como mostra o teste *in-sample*.

Em relação aos tempos computacionais, a Tabela 11 mostra que um problema com 50 cenários pode ser resolvido em torno de 45s. A Tabela 12 mostra que um problema com 100 cenários pode ser resolvido em torno de 90s. A Tabela 13 mostra que um problema com 200 cenários pode ser resolvido em torno de 180s. Estes tempos podem ser considerados razoáveis.

As Figuras 10, 11, 12, 13 e 14 apresentam o valor esperado e o desvio padrão dos métodos de geração de cenários MC, RC e QMC para avaliar sua estabilidade. Estas figuras mostram que o método QMC apresenta uma melhor estabilidade tanto nos testes *in-sample* e *out-of-sample* em comparação com o MC e a RC. Este resultado corrobora as conclusões de Glasserman (2003) sobre a utilidade do método QMC em problemas com variáveis aleatórias de dimensão elevada.

Na Figura 13, no teste *in-sample*, o desvio padrão do QMC tem uma queda quase linear a partir de US\$ 5.733 considerando 20 cenários até US\$ 713

considerando 200 cenários. De maneira análoga, na Figura 14, no teste *out-of-sample*, o desvio padrão do QMC apresenta uma queda a partir de US\$ 101 considerando 50 cenários até US\$ 0 considerando 200 cenários.

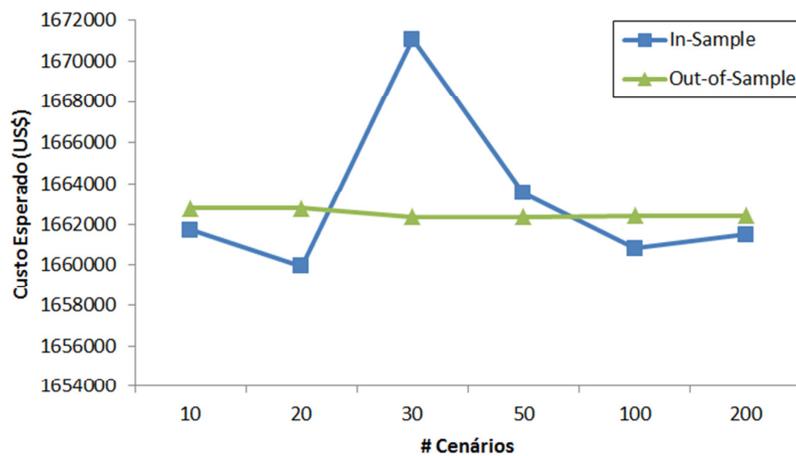


Figura 10 – Custo esperado do método MC para os testes de estabilidade da Instância N.1

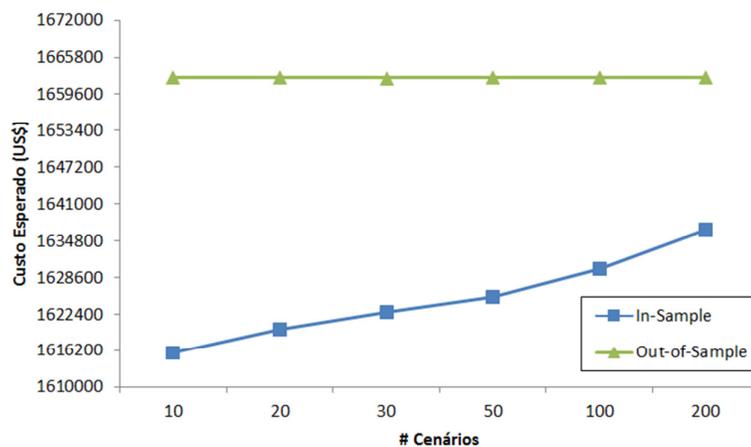


Figura 11 – Custo esperado do método de RC para os testes de estabilidade da Instância N.1

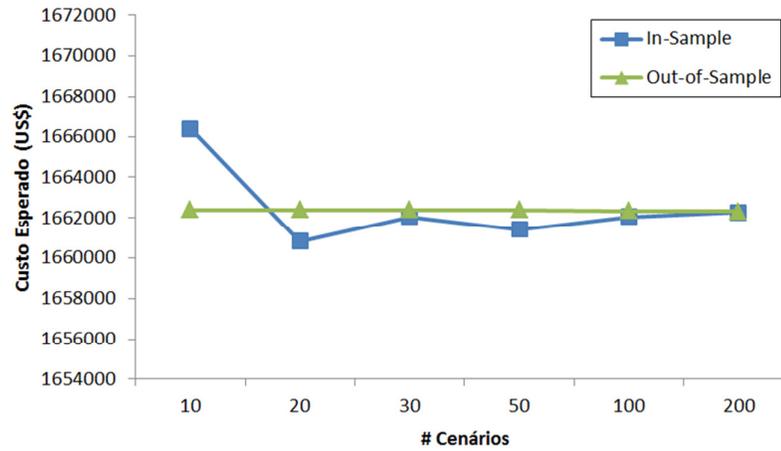


Figura 12 – Custo esperado do método QMC para os testes de estabilidade da Instância N.1

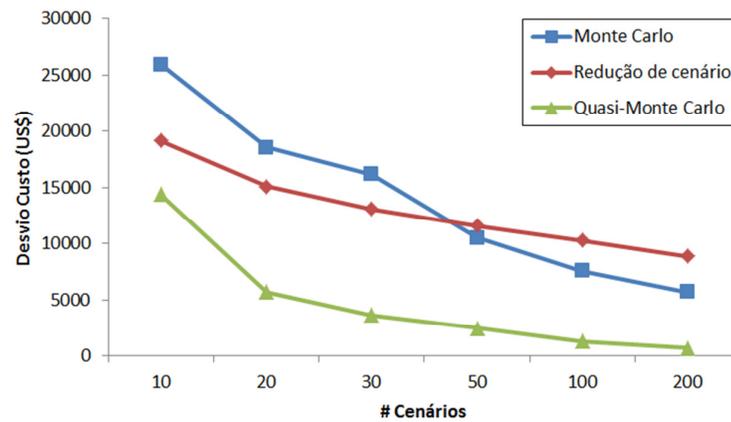


Figura 13 – Desvio do Custo do método MC, RC e QMC para o teste de estabilidade *in-sample* da Instância N.1

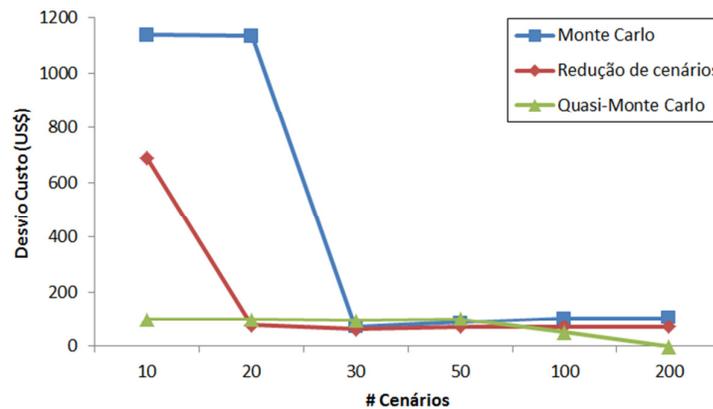


Figura 14 – Desvio do Custo do método MC, RC e QMC para o teste de estabilidade *out-of-sample* da Instância N.1

A solução de primeiro estágio encontrada pelo QMC na Tabela 13 sugere que esta é a solução ótima de primeiro estágio “verdadeira”, com um valor ótimo de US\$ 1.662.322 e que pode ser avaliada em 4.536,3s como é mostrado no teste *out-of-sample*. Portanto, os testes de estabilidade indicam que o QMC é o método de geração de cenário mais adequado e que não devem ser geradas replicações com menos de 100 cenários para resolver a instância proposta com precisão.

Nos próximos experimentos, o QMC será utilizado como método de geração de cenários, devido ao rendimento mostrado nesta instância, assim como também, a mesma metodologia empregada para obtenção de soluções.

### **5.6.2** **Instância N.2**

Nesta segunda instância foi considerado um problema com 150 poços e 5 sondas disponíveis por classe. A Tabela 14 apresenta os resultados computacionais dos testes *in-sample* e *out-of-sample* para QMC com diferentes números de cenários.

Tabela 14 – Resultados computacionais para a Instância N.2

# Cenários	<i>In-sample</i>			<i>Out-of-sample</i>						
	Sondas utilizadas			Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
C3	C4	C5								
10	5	4	1	20	82,1	2.194.905	23,0	82,2	2.198.786	6.172,8
	5	5	1	10	88,4	2.203.514	21,0	88,7	2.198.644	6.610,1
Média					84,2	2.197.774	22,4	84,3	2.198.739	6.318,6
Desv.					3,0	17.013		3,1	67	
20	5	4	1	16	82,3	2.195.509	59,5	82,2	2.198.786	6.172,8
	5	5	1	14	88,6	2.199.949	54,8	88,7	2.198.644	6.610,1
Média					85,2	2.197.581	57,3	85,2	2.198.720	6.376,9
Desv.					3,1	7.812		3,3	71	
30	5	4	1	17	82,1	2.196.104	82,9	82,2	2.198.786	6.172,8
	5	5	1	13	88,5	2.201.121	84,6	88,7	2.198.644	6.610,1
Média					84,9	2.198.278	87,7	85,0	2.198.725	6.362,3
Desv.					3,1	4.909		3,2	70	
50	5	4	1	4	82,3	2.196.976	76,8	82,2	2.198.786	6.172,8
	5	5	1	26	88,6	2.200.327	76,7	88,7	2.198.644	6.610,1
Média					87,8	2.199.880	76,7	87,8	2.198.663	6.551,8
Desv.					2,2	3.926		2,2	48	
100	5	4	1	3	82,2	2.197.571	156,3	82,2	2.198.786	6.172,8
	5	5	1	27	88,7	2.198.951	149,7	88,7	2.198.644	6.610,1
Média					88,0	2.198.813	150,3	88,0	2.198.659	6.566,4
Desv.					1,9	1.354		2,0	43	
200	5	4	1	1	82,2	2.198.767	287,6	82,2	2.198.786	6.172,8
	5	5	1	29	88,7	2.198.483	274,6	88,7	2.198.644	6.610,1
Média					88,5	2.198.492	275,1	88,5	2.198.649	6.595,5
Desv.					1,2	781		1,2	25	

A Tabela 14 mostra que na análise preliminar (considerando 10, 20 e 30 cenários), as mesmas duas soluções foram encontradas. A primeira solução com 5 sondas C3, 4 sondas C4 e 1 sonda C5; e a segunda solução com 5 sondas C3, 5 sondas C4 e 1 sonda C5. Em relação aos tempos computacionais, tem-se que um problema com 10, 20 e 30 cenários pode ser resolvido em torno de 22s, 57s e 88s respectivamente.

Para os casos com 50, 100 e 200 cenários observa-se que a frequência da segunda solução aumenta. Para o caso maior com 200 cenários, no teste *in-sample*, o número de poços atendidos em média é de 88,5 (com desvio de 1,2), o custo total esperado é de US\$ 2.198.492 (com desvio de US\$ 781) e o tempo de execução média de 275,1s. No teste *out-of-sample*, o número de poços atendidos é

de 88,5 em média (com desvio de 1,2), o custo total esperado é de US\$ 2.198.649 (com desvio de US\$ 25) e o tempo de execução média é de 6.595,5s.

As Figuras 15, 16 e 17 ilustram a estabilidade do método QMC. A Figura 15 mostra que o problema é estabilizado a partir de 100 cenários. Na Figura 16, o desvio padrão apresenta uma queda quase linear entre 20 e 200 cenários no teste *in-sample*. Na Figura 17, o desvio padrão apresenta uma queda entre 30 e 200 cenários no teste *out-of-sample*. A avaliação sugere que não devem ser geradas replicações com menos de 200 cenários, pois essa quantidade de cenários produz limites inferiores do valor ótimo do problema como mostra a Figura 15. Note que para 200 cenários, uma das soluções possui uma frequência de 29 replicações.

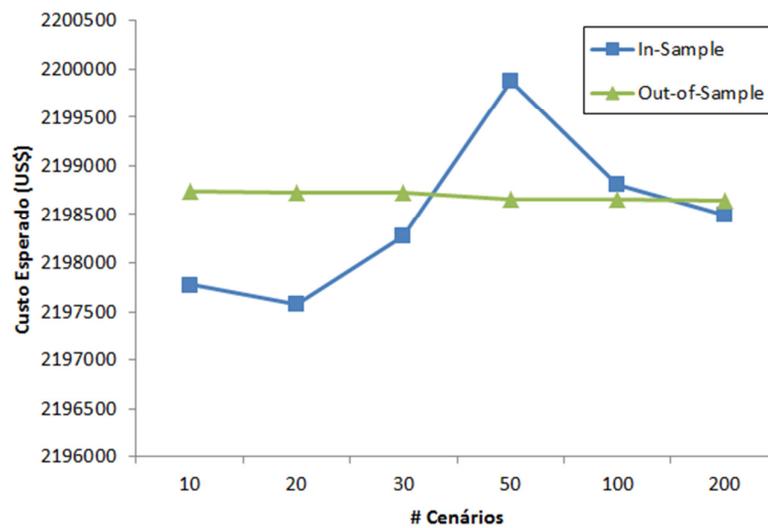


Figura 15 – Custo esperado do método QMC para os testes de estabilidade da Instância N.2

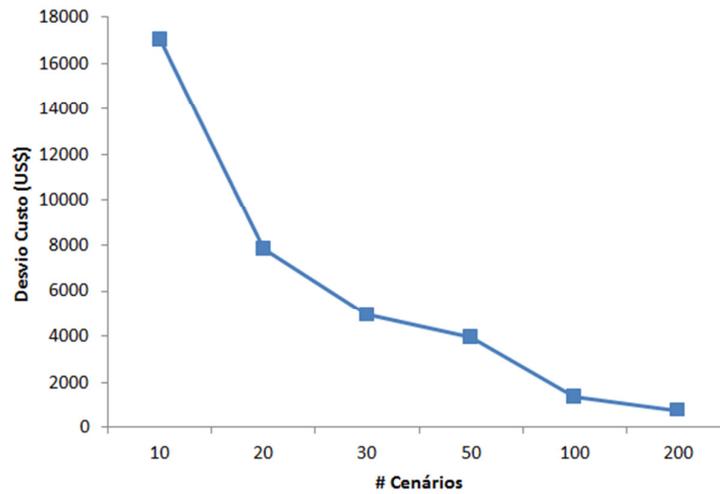


Figura 16 – Desvio do Custo do método QMC para o teste de estabilidade *in-sample* da Instância N.2

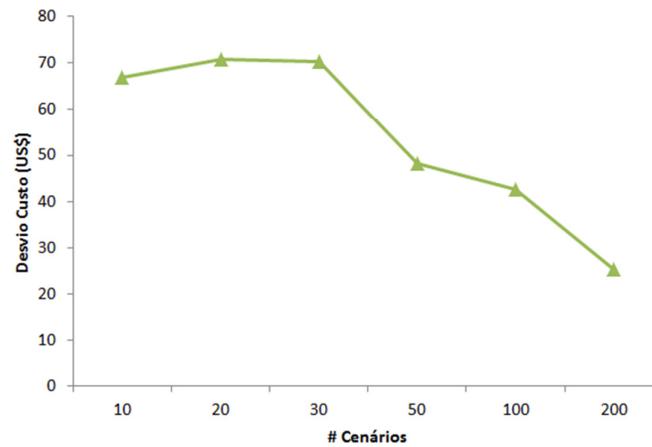


Figura 17 – Desvio do Custo do método QMC para o teste de estabilidade *out-of-sample* da Instância N.2

### 5.6.3 Instância N.3

A terceira instância considera um problema com 200 poços e 5 sondas disponíveis por classe. A Tabela 15 apresenta os resultados computacionais com o método QMC para diferente número de cenários.

Tabela 15 – Resultados computacionais para a Instância N.3

# Cenários	Sondas utilizadas			<i>In-sample</i>				<i>Out-of-sample</i>		
	C3	C4	C5	Freq	Atend	Custo (US\$)	Tp (s)	Atend	Custo (US\$)	Tp (s)
10	5	4	2	6	93,7	2.638.731	26,7	93,7	2.648.005	6.989,3
	5	5	2	24	100,5	2.648.313	29,3	100,9	2.647.349	7.127,1
Média					99,1	2.646.396	28,8	99,5	2.647.480	7.099,5
Desv.					2,8	13.664		2,9	262	
20	5	4	2	6	93,7	2.643.481	82,3	93,7	2.648.005	6.989,3
	5	5	2	24	100,5	2.650.144	81,6	100,9	2.647.349	7.127,1
Média					99,1	2.648.811	81,8	99,5	2.647.480	7.099,5
Desv.					2,8	10.564		2,9	262	
30	5	4	2	1	93,8	2.641.397	108,8	93,7	2.648.005	6.989,3
	5	5	2	29	100,6	2.648.006	109,8	100,9	2.647.349	7.127,1
Média					100,4	2.647.785	109,8	100,7	2.647.371	7.122,5
Desv.					1,3	5.430		1,3	118	
50	5	5	2	30	100,9	2.646.953	68,8	100,9	2.647.349	7.127,1
Média					100,9	2.646.953	68,8	100,9	2.647.349	7.127,1
Desv.					0,2	3.630		0,0	0	
100	5	5	2	30	100,9	2.647.195	141,8	100,9	2.647.349	7.127,1
Média					100,9	2.647.195	141,8	100,9	2.647.349	7.127,1
Desv.					0,1	1.982		0,0	0	
200	5	5	2	30	100,9	2.647.238	286,3	100,9	2.647.349	7.127,1
Média					100,9	2.647.238	286,3	100,9	2.647.349	7.127,1
Desv.					0,1	937		0,0	0	

A análise preliminar da Tabela 15 mostra que duas soluções foram encontradas. No caso de 30 cenários, observa-se uma clara tendência por uma solução. Aqui um problema com 10, 20 e 30 cenários pode ser resolvido em torno de 29s, 82s e 110s respectivamente. Para os casos seguintes, esta solução possui uma frequência de 30 replicações. Aqui, o problema com 50, 100 e 200 cenários pode ser resolvido aproximadamente em 69s, 142s e 286s respectivamente.

A estabilidade do QMC é verificada nas Figuras 18, 19 e 20. A Figura 18 mostra que o problema possui uma boa estabilidade a partir de 50 cenários. Nas Figuras 19 e 20 o desvio padrão apresenta uma queda quase linear no teste *in-sample* e *out-of-sample*, chegando a zero neste último teste a partir de 50 cenários. Aqui também a avaliação sugere que não devem ser geradas replicações com menos de 100 cenários.

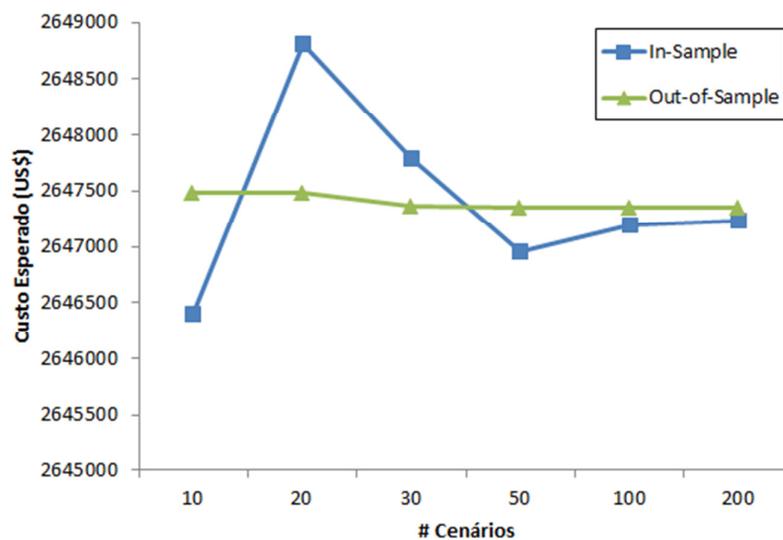


Figura 18 – Custo esperado do método QMC para os testes de estabilidade da Instância N.3

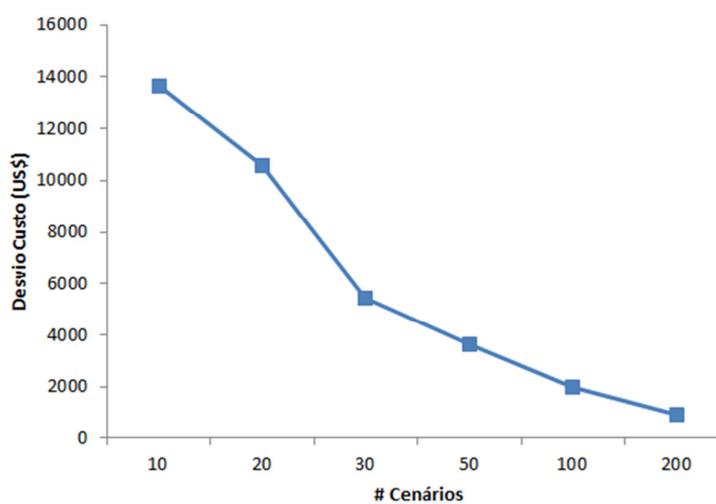


Figura 19 – Desvio do Custo do método QMC para o teste de estabilidade *in-sample* da Instância N.3

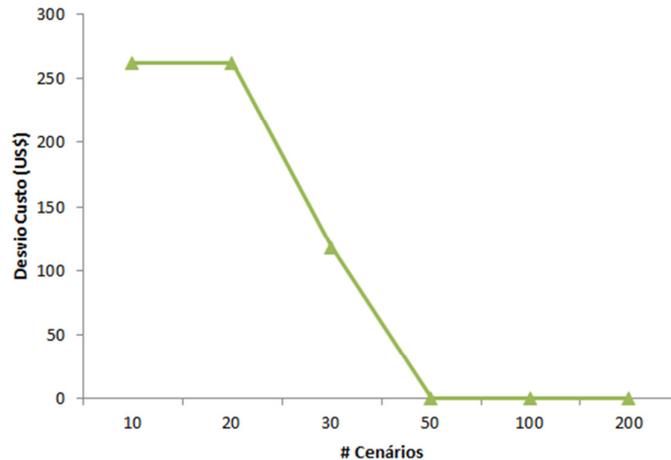


Figura 20 – Desvio do Custo do método QMC para o teste de estabilidade *out-of-sample* da Instância N.3

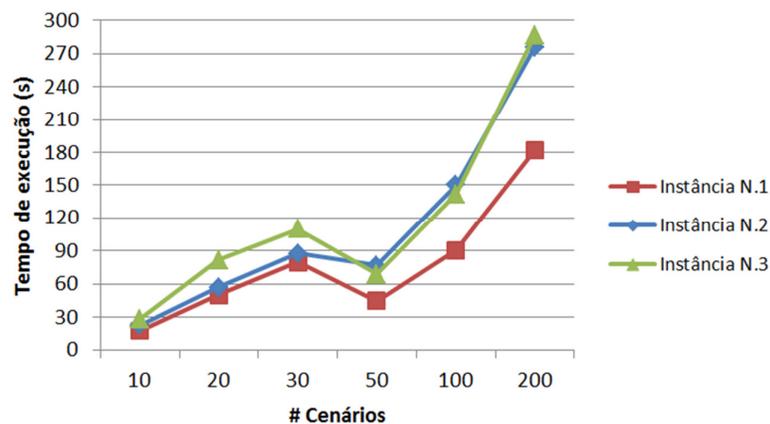
Em geral, as instâncias consideradas obtiveram bons resultados com 100 cenários, com pouca diferença entre o custo esperado nos testes *in-sample* e *out-of-sample*. Também foi observado que desvio padrão do custo do QMC decai segundo uma função aparentemente linear com respeito ao número de cenários a partir de certo ponto. Esta informação pode ser útil para desenho de experimentos para diferentes níveis de variabilidade.

A Tabela 16 apresenta as estatísticas das instâncias N.1, N.2 e N.3, utilizando a quantidade de cenários estabelecidos de acordo aos testes de estabilidade, isto é, para instância N.1 foi gerada uma instância com 100 cenários, para instância N.2 foi gerada uma instância com 200 cenários e para instância N.3 foi gerada uma instância com 100 cenários. Nesta tabela são reportados os valores médios, mínimos e máximos da porcentagem de utilização das sondas no horizonte de tempo, o tempo de espera dos poços para serem atendidos, o tamanho da fila de espera e a perda de produção no horizonte de tempo.

Tabela 16 – Estatísticas das instâncias N.1, N.2 e N.3

		% Utilização	Tempo de espera (dias)	Tamanho da fila	Perda de produção (m <sup>3</sup> )
Instância N.1	Min	92	3,8	7,0	3.557
	Média	94	4,4	7,8	4.205
	Max	96	4,9	8,6	5.089
Instância N.2	Min	93	3,2	7,2	4.989
	Média	95	3,8	8,1	5.908
	Max	96	4,4	8,9	7.175
Instância N.3	Min	94	2,9	7,7	6.446
	Média	95	3,3	8,4	7.359
	Max	96	3,7	9,3	8.394

A Figura 21 apresenta o tempo de execução médio do teste *in-sample* para diferente número de cenários, considerando as instâncias N.1, N.2 e N.3. Nesta figura, observa-se um decaimento do tempo computacional considerando 50 cenários, sendo inclusive menor que o tempo computacional considerando 30 cenários nas três instâncias. Este decaimento é devido à redução do espaço de soluções após a análise preliminar. O aumento do número de variáveis e restrições de acordo ao número de cenários é refletido no crescimento do tempo computacional entre 10 e 30 cenários, e entre 50 e 200 cenários, no entanto, não é produzido um severo incremento como esperado, evidenciando que é possível tratar computacionalmente um problema estocástico com um número elevado de cenários com a metodologia empregada.

Figura 21 – Tempo de execução médio *in-sample* para as instâncias N.1, N.2 e N.3

## 6 Conclusões e trabalhos futuros

Nesta tese foi abordado o problema de intervenção em poços terrestres de petróleo, o qual é um dos mais desafiadores na indústria de petróleo e gás. A dificuldade presente no problema, por ser da classe *NP-hard*, faz com que na literatura sejam encontrados muitos trabalhos propondo diversas heurísticas e metaheurísticas. Embora as heurísticas e metaheurísticas possam obter bons resultados para instâncias de pequeno e médio porte, estas não são capazes de obter soluções ótimas para instâncias de grande porte. Assim, com a finalidade de dar um novo enfoque para abordar o problema, nesta tese foram desenvolvidos três modelos matemáticos eficientes, tratando ambos os casos determinístico e estocástico.

O primeiro modelo proposto trata o Problema de Otimização de Itinerário de Sondas para poços terrestres de petróleo. O modelo é um aprimoramento do modelo proposto por Costa e Ferreira Filho (2004). Nos experimentos computacionais o desempenho do modelo foi comparado com as metaheurísticas *Genetic Algorithm*, *Memetic Algorithm* e *Simulated Annealing*. Os resultados mostram que o modelo proposto foi capaz de determinar o valor ótimo de todas as instâncias consideradas, incluindo aquelas de grande porte, onde as metaheurísticas apenas conseguiram valores aproximados. Considerando os tempos computacionais, o modelo resolveu todas as instâncias em tempos reduzidos, demonstrando ser mais eficiente perante aos demais métodos.

O segundo modelo considera o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas para poços terrestres de petróleo. Os experimentos computacionais foram realizados em grupos de instâncias propostas de médio e grande porte, variando o horizonte de tempo e o preço de petróleo. A análise dos resultados mostra que uma variação no preço do petróleo ou no horizonte de tempo provoca uma variação na decisão do tamanho da frota de sondas, tornando vantajoso aumentar a frota quando o preço do petróleo aumenta e tornado preferível diminuir a frota nos casos quando aumenta o horizonte de tempo. Todas as instâncias testadas foram resolvidas em tempos computacionais

satisfatórios (20s no pior caso). Os resultados corroboram a eficácia do modelo proposto.

O terceiro modelo é uma abordagem estocástica do segundo modelo e considera o Problema de Otimização de Itinerário e Dimensionamento de Frota de Sondas sob incerteza para poços terrestres de petróleo. O problema é formulado como um modelo de programação estocástica de dois estágios, onde o tempo de intervenção dos poços é considerado incerto. A geração de cenários é realizada pelos métodos *Monte Carlo*, Redução de Cenário e *Quasi-Monte Carlo*, aplicando neles a metodologia proposta por Kaut e Wallace (2003) para avaliar a estabilidade dos resultados e estabelecer o número de cenários adequados para resolver o problema com precisão. A avaliação dos métodos de geração de cenários sugere que o *Quasi-Monte Carlo* é o mais apropriado para tratar o problema, o qual considera uma variável aleatória de dimensão elevada. O *Quasi-Monte Carlo* conseguiu convergir mais rapidamente a diferença dos outros métodos. Nos experimentos foi observado que o *Monte Carlo* converge em menor proporção que o *Quasi-Monte Carlo* e que o método de Redução de Cenários converge lentamente, isto devido à perda de informação no processo de contração e atribuição de novas probabilidades aos cenários. Para verificar a eficiência do terceiro modelo, este foi testado em instâncias propostas de grande porte, conseguindo encontrar as soluções ótimas destas mediante uma análise preliminar, que consiste em resolver o problema com um número básico de cenários e que visa reduzir o espaço de busca para compensar o incremento do tamanho do problema quando for resolvido com um número maior de cenários. Com esta metodologia, as instâncias foram resolvidas em um tempo computacional satisfatório.

A vantagem dos modelos matemáticos propostos é que são capazes de proporcionar soluções ótimas em um tempo computacional razoável para problemas reais com um número elevado de poços e diferente tamanho de frota de sondas. Dessa forma também, as novas instâncias geradas e descritas no Apêndice serviram de apoio para os problemas difíceis tratados nesta tese, e podem ser úteis para futuras pesquisas.

Consequentemente, os modelos propostos corroboram sua utilidade como uma ferramenta para serem usados em casos reais, realizando uma programação

das intervenções nos poços de maneira confiável e rápida. Ressalta-se que os modelos propostos também podem ser empregados em uma grande variedade de problemas de programação de atividades por se tratar de enfoques baseados no escalonamento de máquinas em paralelo.

Para trabalhos futuros, os pontos seguintes seriam importantes pesquisar:

1. Considerar outras distribuições de probabilidade do tempo de intervenção que sejam baseadas em casos reais;
2. Estudar o impacto do preço do petróleo quando é considerado como uma variável aleatória em longos horizontes de tempo. Como foi verificado no Capítulo 4, a variação do preço do petróleo pode afetar a tomada de decisão sobre quantas sondas devem ser alocadas em uma região.
3. Utilizar outros métodos de geração de cenários, por exemplo, o *Moment Matching*;
4. Realizar um *stress test* para os modelos propostos, aumentando o número de poços e o horizonte de tempo, com a finalidade de conhecer o desempenho dos modelos nestas condições;
5. Propor modelos eficientes para casos de campos marítimos de petróleo, adicionando novas características operacionais, como por exemplo, as coordenadas geográficas dos poços e das sondas, a lâmina de água, a profundidade do poço, o índice de produtividade das sondas, velocidade média de deslocamento da sonda, capacidade de intervenção da sonda e a presença de H<sub>2</sub>S.
6. Analisar a dinâmica do problema, isto é, considerar que o itinerário possa ser reprogramado. A demanda por serviços de manutenção não seria previamente conhecida por completo, cada falha em um poço seria verificada em tempo real e o poço seria examinado para ser incluído no planejamento inicial, provocando se for o caso, uma reprogramação (reotimização do problema).

## 7

### Referências bibliográficas

ACCIOLY, R. M. S.; CHIYOSHI, F. Y. Simulando operações de manutenção em poços de petróleo. **In: Proceedings of XVIII ENEGEP**, p. 1–5, Rio de Janeiro, Niteroi, 1998.

AHMED, S.; SHAPIRO, A. The sample average approximation method for stochastic programs with integer recourse. **SIAM Journal of Optimization**, v. 12, p. 479–502, 2002.

ALOISE, D.; NORONHA, T. F.; MAIA, R. S.; BITTENCOURT, V. G.; ALOISE, D. J. Heurísticas de colônia de formigas com path-relinking para o problema de otimização da alocação de sondas de produção terrestre – SPT. **XXXIV Simpósio Brasileiro de Pesquisa Operacional**, Rio de Janeiro, RJ, 2002.

ALOISE, D. J.; ALOISE, D.; ROCHA, C. T. M.; RIBEIRO, C. C.; RIBEIRO, J. C.; MOURA, L. S. S. Scheduling workover rigs for onshore oil production. **Discrete Applied Mathematics**, v. 154(5), p. 695–702, 2006.

ALVES, V. R. F. M.; FERREIRA FILHO, V. J. M. Proposta de algoritmo genético para a solução do problema de roteamento e seqüenciamento de sondas de manutenção. **XXXVIII Simpósio Brasileiro de Pesquisa Operacional**, Goiás, Goiânia, 2006.

BASSI, H. V. **Simulação-Otimização e Reconexão por caminhos aplicadas ao gerenciamento de sondas de intervenção**. Dissertação de Mestrado em Engenharia de Produção. COPPE/UFRJ, Rio de Janeiro, 2010.

BASSI, H. V.; FERREIRA FILHO, V. J. M.; BAHIENSE, L. Planning and scheduling a fleet of rigs using simulation–optimization. **Computers & Industrial Engineering**, v. 63, p. 1074–1088, 2012.

BARNES, J. W.; BRENNAN, J. J.; KNAP, R. M. Scheduling a backlog of oil well workovers. **Journal of Petroleum Technology**, v. 29(12), p. 1651–1653, 1977.

BERALDI, P.; BRUNI, M. E. A clustering approach for scenario tree reduction: an application to a stochastic programming portfolio optimization problem. **TOP**, v. 22, p. 934–949, 2014.

BERALDI, P.; GRANDINETTI, L.; EPICOCO, I.; VIOLI, A.; BRUNI, M. E. An advanced system for portfolio optimisation. **International Journal of Grid and Utility Computing**, v. 5(1), p. 21–32, 2014.

BISSOLI, D. C. **Uma abordagem heurística para o problema de roteamento de sondas de intervenção bi-objetivo**. Dissertação de Mestrado em Energia, Universidade Federal do Espírito Santo, Espírito Santo, São Mateus, 2014.

BISSOLI, D. C.; CHAVES, G. L. D.; RIBEIRO, G. M. Drivers to the workover rig problem. **Journal of Petroleum Science and Engineering**, v. 139, p. 13-22, 2016.

BISSOLI, D. C.; VIERIA, B. S.; CHAVES, G. L. D.; RIBEIRO, G. M. Um ALNS para o problema de roteamento de sondas de intervenção bi-objetivo. **XLVI Simpósio Brasileiro de Pesquisa Operacional**, Bahia, Salvador, 2014.

BORCHARDT, M. **Algoritmos evolucionários na solução do problema da programação de sondas de produção**. Dissertação de Mestrado em Sistemas e Computação. Universidade Federal do Rio Grande do Norte, Natal, 2002.

CHHIKARA, R. S; FOLKS, J. L. **The Inverse Gaussian Distribution: Theory, Methodology, and Application**. New York: Marcel Dekker, 1989.

COSTA, L. R. **Soluções para o Problema de Otimização de Itinerário de Sondas**. Dissertação de Mestrado em Engenharia de Produção. COPPE/UFRJ, Rio de Janeiro, 2005.

COSTA, L. R.; FERREIRA FILHO, V. J. M. Uma heurística para o problema do planejamento de itinerários de sondas em intervenções de poços de petróleo. **XXXVI Simpósio Brasileiro de Pesquisa Operacional**, Minas Gerais, São João del Rei, 2004.

COSTA, L. R.; FERREIRA FILHO, V. J. M. Uma heurística de montagem dinâmica para o problema de otimização de itinerários de sondas. **XXXVII Simpósio Brasileiro de Pesquisa Operacional**, Rio Grande do Sul, Gramado, 2005.

COOK, J. D. Notes on the negative binomial distribution. 2009. Disponível em: <[www.johndcook.com/negative\\_binomial.pdf](http://www.johndcook.com/negative_binomial.pdf)> Acesso em: 1 jul. 2016.

DAVARI-ARDAKANI, H.; AMINNAYERI, M.; SEIFI, A. Multistage portfolio optimization with stocks and options. **International Transactions in Operational Research**, v. 23, p. 593–622, 2016.

DOURO, R. F.; LORENZONI, L. L. Um algoritmo genético-2opt aplicado ao problema de otimização de itinerário de sondas de produção terrestre. **XLI Simpósio Brasileiro de Pesquisa Operacional**, Bahia, Porto Seguro, 2009.

DU, J.; LEUNG, J. Y.-T. Minimizing total tardiness on one machine is NP-hard. **Mathematics of Operations Research**, v. 15, p. 483–495, 1990.

DUHAMEL, C.; SANTOS, A. C.; GUEDES, L. M. Models and hybrid methods for the onshore wells maintenance problem. **Computers & Operations Research**, v. 39, p. 2944–2953, 2012.

DUPACOVÁ, J.; GROWE-KUSKA, N.; ROMISCH, W. Scenario reduction in stochastic programming: An approach using probability metrics. **Mathematical Programming Series A**, v. 95, p. 493–511, 2003.

FARIA, E.; FLETEN, S. E. Day-ahead market bidding for a Nordic hydropower producer: taking the Elbas market into account. **Computational Management Science**, v. 8, p. 75–101, 2011.

FLETEN, S. E.; HAUGSTVEDT, D.; STEINSBØ, J. A.; BELSNES, M. M.; FEISCHMANN, F. Bidding hydropower generation: Integrating short- and long-term scheduling. **17th Power Systems Computation Conference**, 2011.

GLASSERMAN, P. **Monte Carlo Methods in Financial Engineering**. New York: Springer, 2003.

GOUVÊA, E. F.; GOLDBARG, M. C.; COSTA, W. E. Algoritmos evolucionários na solução do problema de otimização do emprego de sondas de produção em poços de petróleo. **XXXIV Simpósio Brasileiro de Pesquisa Operacional**, Rio de Janeiro, RJ, 2002.

HEITSCH, H.; RÖMISCH, W. Scenario reduction algorithms in stochastic programming. **Computational Optimization and Applications**, v. 24, p. 187–206, 2003.

HEITSCH, H.; RÖMISCH, W. A note on scenario reduction for two-stage stochastic programs. **Operations Research Letters**, v. 35, p. 731–738, 2007.

IRGENS, M.; GUZMAN, R. P.; STAMATOPOULOS, J.; JACKSON, K. Optimization for operational decision support: The rig fleet management case. **In: Proceedings of SPE annual technical conference and exhibition**, p. 1–14, 2008.

IRGENS, M.; LAVENUE, W. Use of advanced optimization techniques to manage a complex drilling schedule. **In: Proceedings of SPE annual technical conference and exhibition**, p. 1–9, 2007.

KAUT, M.; WALLACE, S. W. Evaluation of scenario-generation methods for stochastic programming, **Stochastic Programming E-Print Series**, n. 14, 2003.

KAUT, M.; WALLACE, S. W.; VLADIMIROU, H.; ZENIOS, S. Stability analysis of portfolio management with conditional value-at-risk. **Quantitative Finance**, v. 7(4), p. 397–409, 2007.

LINDEROTH, J.; SHAPIRO, A.; WRIGHT, S. The empirical behavior of sampling methods for stochastic programming. **Annals of Operations Research**, v. 142, p. 215–241, 2006.

LÖHNDORF, N. An empirical analysis of scenario generation methods for stochastic optimization. **European Journal of Operational Research**, v. 255(1), p. 121–132, 2016.

MAGGIONI, F.; KAUT, M.; BERTAZZI, L. Stochastic optimization models for a single-sink transportation problem. **Computational Management Science**, v. 6(2), p. 251–267, 2009.

MAIA, R. S.; GONZAGA, C. S. M.; LIMA JÚNIOR, F. C.; BITTENCOURT, V. G. Otimização das intervenções em poços de petróleo por sondas de produção terrestre: Busca Tabu. **XXXIV Simpósio Brasileiro de Pesquisa Operacional**, Rio de Janeiro, RJ, 2002.

MONEMI, R. N.; DANACH, K.; KHALIL, W.; GELAREH, S.; LIMA, F. C. JR.; ALOISE, D. J. Solution methods for scheduling of heterogeneous parallel machines applied to the workover rig problem. **Expert Systems with Applications**, v. 42, p. 4493–450, 2015.

MØRCH, O.; FAGERHOLT, K.; PANTUSO, G.; RAKKE, J. Maximizing the rate of return on the capital employed in shipping capacity renewal. **Omega**, v. 67, p. 42–53, 2017.

NEVES, T. A. **Heurísticas com memórias adaptativas aplicadas ao problema de roteamento e scheduling de sondas de manutenção**. Dissertação de Mestrado em Computação, Universidade Federal Fluminense, Niterói, 2007.

OLIVEIRA, E. F.; PAGOTO, F. B.; SILVA, F. T.; LORENZONI, L. L. Scatter search aplicado ao problema de otimização da alocação de sondas de produção em poços de petróleo. **XXVII Encontro Nacional de Engenharia de Produção**, Paraná, Foz de Iguaçu, 2007.

OLIVEIRA, F.; NUNES, P. M.; BLAJBERG, R.; HAMACHER, S. A framework for crude oil scheduling in an integrated terminal-refinery system under supply uncertainty. **European Journal of Operational Research**, v. 252, p. 635–645, 2016.

PACHECO, A. V. F. **Métodos de solução para o problema da alocação de sondas a poços de petróleo**. Trabalho de conclusão de curso em Engenharia de Produção, Universidade Federal do Espírito Santo, São Mateus, 2011.

PACHECO, A. V. F.; FILHO, A. C. T. D.; RIBEIRO, G. M. Uma heurística para o problema da alocação de sondas de produção em poços de petróleo. **XXIX Encontro Nacional de Engenharia de Produção**, Bahia, Salvador, 2009.

PACHECO, A. V. F.; RIBEIRO, G. M.; MAURI, G. R. A GRASP with path-relinking for the workover rig scheduling problem. **International Journal of Natural Computing Research**, v. 1(2), p. 1–14, 2010.

PAIVA, R. O. **Otimização do itinerário de sondas de intervenção**. Dissertação de Mestrado em Engenharia de Petróleo. UNICAMP, Campinas, 1997.

PAIVA, R. O.; SCHIOZER, D. J.; BORDALO, S. N. Optimizing the itinerary of workover rigs. **In: Proceedings of 16th World Petroleum Congress**, Canada, Calgary, 2000.

PERBOLI, G.; GOBBATO, L.; MAGGIONI, F. A progressive hedging method for the multi-path travelling salesman problem with stochastic travel times. **IMA Journal of Management Mathematics**, p. 1-22, 2015.

PÉREZ M.; OLIVEIRA, F.; HAMACHER, S. A new mathematical model for the workover rig scheduling problem. **Pesquisa Operacional**, v. 36(2), p. 241–257, 2016.

RIBEIRO G. M.; DESAULNIERS, G.; DESROSIERS, J. A Branch-Price-and-Cut Algorithm for the workover rig routing problem. **Computers and Industrial Engineering**, v. 39, p. 3305–3315, 2012.

RIBEIRO, G. M.; DESAULNIERS, G.; DESROSIERS, J.; VIDAL, T.; VIEIRA, B. S. Efficient heuristics for the workover rig routing problem with a heterogeneous fleet and a finite horizon, **Journal of Heuristics**, v. 20, p. 677–708, 2014.

RIBEIRO, G. M.; MAURI, G. R.; LORENA, L. A. M. A simple and robust simulated annealing algorithm for scheduling workover rigs on onshore oil fields. **Computers and Industrial Engineering**, v. 60, p. 519–526, 2011.

RIBEIRO, G. M.; LAPORTE G.; MAURI, G. R. A comparison of three metaheuristics for the workover rig routing problem. **European Journal of Operational Research**, v. 220, p. 28–36, 2012.

SABRY, G. A. **Um estudo algorítmico da programação da intervenção de sondas de produção**. Dissertação de Mestrado em Sistemas e Computação, Universidade Federal do Rio Grande do Norte, Natal, 2012.

SABRY, G. A.; GOLDBARG, M. C.; GOLDBARG, E. F. G. Um estudo algorítmico do problema da programação de sondas de produção. **XXXIV Simpósio Brasileiro de Pesquisa Operacional**, Rio de Janeiro, RJ, 2012.

SELJOM, P.; TOMASGARD, A. Short-term uncertainty in long-term energy system models - A case study of wind power in Denmark. **Energy Economics**, v. 49, p. 157–167, 2015.

SHAPIRO, A.; HOMEM-DE-MELLO, T. A simulation-based approach to two-stage stochastic programming with recourse. **Mathematical Programming**, v. 81, p. 301–325, 1998.

SILVA, G. C.; BAHIANSE, L.; OCHI, L. S.; BOAVENTURA-NETTO, P. O. The dynamic space allocation problem: Applying hybrid GRASP and Tabu search metaheuristics. **Computers & Operations Research**, v. 39, p. 671–677, 2012.

SMITH, W. E. Various optimizers for single-stage production. **Naval Research Logistics Quarterly**, v. 3, p. 59–66, 1956.

SOARES, W. K. S.; COSTA, A. P. C. S.; ALOISE, D. J. Considerações sobre o problema do agendamento de sondas de manutenção “onshore” e proposição de instâncias. **XLIII Simpósio Brasileiro de Pesquisa Operacional**, Rio de Janeiro, São Paulo, Ubatuba, 2011.

THOMAS, J. E. **Fundamentos de Engenharia de Petróleo**. Rio de Janeiro: Editora Interciência, 2001.

TSITSIKLIS, J. N. Special cases of traveling salesman and repairman problems with time windows. **Networks**, v. 22, p. 263–283, 1992.

VESPUCCI, M. T.; MAGGIONI, F.; BERTOCCHI, M. I.; INNORTA, M. A stochastic model for the daily coordination of pumped storage hydro plants and wind power plants. **Annals of Operations Research**, v. 193(1), p. 91–105, 2012.

VOJVODIC, G.; JARRAH, A. I.; MORTON, D. P. Forward thresholds for operation of pumped-storage stations in the real-time energy market. **European Journal of Operational Research**, v. 254, p. 253–268, 2016.

## 8 Apêndice

### Dados para os problemas

A seguir são descritas as curvas de probabilidade do tempo de intervenção e da vazão de petróleo construídas por Costa (2005), além de outros parâmetros utilizados nesta tese.

Os valores do tempo de intervenção (dias $\times$ 10) são gerados a partir de uma curva de probabilidade *Negative Binomial* (Cook, 2009):

$$f(x, r, pr) = \binom{x+r-1}{x} pr^r (1-pr)^x$$

Onde  $x \in \mathbb{Z}^+$  é uma variável aleatória,  $r > 0$  é o número sucessos e  $0 < pr < 1$  é a probabilidade de sucesso. Os valores atribuídos são:  $r = 3$  e  $pr = 0,14$ . Os valores de gerados de  $x$  são arredondados para serem múltiplos de meio-dia com um valor mínimo de 1 dia.

Os valores da vazão de petróleo (m<sup>3</sup>/dia) são gerados a partir de uma curva de probabilidade *Inverse Gaussian* (Chhikara & Folks, 1989):

$$f(x, \mu, \lambda) = \left[ \frac{\lambda}{2\pi x^3} \right]^{1/2} \exp \left\{ \frac{-\lambda(x - \mu)^2}{2\mu^2 x} \right\} + shift$$

Onde  $x > 0$  é uma variável aleatória,  $\mu > 0$  é a média e  $\lambda > 0$  é um parâmetro de forma. Os valores atribuídos são:  $\mu = 9,04$ ,  $\lambda = 1,84$  e  $shift = -0,16$ . Os valores gerados de  $x$  são arredondados a uma casa decimal com um valor mínimo de 0,1 m<sup>3</sup>/dia.

Outros parâmetros do problema foram estabelecidos com base aos trabalhos de Paiva (1997); Soares et al. (2011); Ribeiro, Desaulniers e Desrosiers (2012); e Bissoli (2014). Foram definidos cinco níveis de serviço requerido para os poços, tomando valores aleatórios entre {1, 2, 3, 4, 5}. As classes de sonda possuem níveis de serviço 3, 4 e 5 com custos horários de US\$ 150, US\$ 200 e US\$ 250 respectivamente.