



OTIMIZAÇÃO DA PRODUÇÃO DE POÇOS DE PETRÓLEO COM GAS LIFT CONTÍNUO

Alex Furtado Teixeira

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Química, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Química.

Orientadores: Argimiro Resende Secchi

Evaristo Chalbaud Biscaia Junior

Rio de Janeiro

Maio de 2013

OTIMIZAÇÃO DA PRODUÇÃO DE POÇOS DE PETRÓLEO COM GAS LIFT
CONTÍNUO

Alex Furtado Teixeira

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

Examinada por:

Prof. Argimiro Resende Secchi, Ph.D.

Prof. Evaristo Chalbaud Biscaia Junior, Ph.D.

Prof. Fernando Luiz Pellegrini Pessoa, Ph.D.

Dr. Mário César Mello Massa de Campos, Ph.D.

RIO DE JANEIRO, RJ - BRASIL

MAIO DE 2013

Teixeira, Alex Furtado

Otimização da Produção de Poços de Petróleo com Gas Lift Contínuo/ Alex Furtado Teixeira. – Rio de Janeiro: UFRJ/COPPE, 2013.

XIII, 98 p.: il.; 29,7 cm.

Orientador: Argimiro Resende Secchi

Evaristo Chalbaud Biscaia Junior.

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Química, 2013.

Referências Bibliográficas: p. 107-111.

1. Introdução. 2. O Processo de Produção de Óleo e Gás. 3. Revisão Bibliográfica. 4. Modelagem e Solução do Problema. 5. Resultados e Discussões. 6. Conclusões e Trabalhos Futuros. I. Secchi, Argimiro Resende *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Química. III. Título.

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

OTIMIZAÇÃO DA PRODUÇÃO DE POÇOS DE PETRÓLEO COM GAS LIFT CONTÍNUO

Alex Furtado Teixeira

Maio/2013

Orientadores: Argimiro Resende Secchi

Evaristo Chalbaud Biscaia Junior

Programa: Engenharia Química

Atualmente, cerca de 70% da produção de petróleo do Brasil vem de poços que produzem com o auxílio do método de elevação artificial conhecido como *gas lift* contínuo. O desenvolvimento de uma estratégia de otimização que maximize a produção destes poços e obedeça às restrições impostas pela planta de processo da plataforma é de extrema importância, devido aos ganhos em escala que ela pode proporcionar. O presente trabalho apresenta uma formulação para o problema considerando uma função objetivo econômica e respeitando as limitações de capacidade da unidade para tratamento dos fluidos produzidos. Uma função objetivo operacional também é formulada e seus resultados são comparados com os da função objetivo econômica, mostrando que a primeira pode gerar perdas financeiras significativas na operação. O problema é solucionado através da aplicação de diferentes algoritmos de otimização e uma comparação dos resultados através de um conjunto de critérios de eficiência é realizada, mostrando que o método da programação quadrática sequencial com o uso de função de regularização apresenta o melhor desempenho, porém, o seu resultado é fortemente influenciado pela estimativa inicial fornecida. Com o objetivo de garantir a escolha da melhor estimativa inicial, propôs-se um método híbrido que apresentou excelentes resultados.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

PRODUCTION OPTIMIZATION OF PETROLEUM WELLS WITH CONTINUOUS GAS LIFT

Alex Furtado Teixeira

May/2013

Advisors: Argimiro Resende Secchi

Evaristo Chalbaud Biscaia Junior

Department: Chemical Engineering

Currently, about 70% of Brazil's petroleum production comes from wells that produce with the aid of an artificial lift method known as continuous gas lift. The development of an optimization strategy that maximizes the production of these wells and obeys the constraints imposed by the platform process plant is of extreme importance due to gains in scale that it can provide. This paper presents a formulation for the problem considering an economic objective function and respecting the limitations of available gas for gas lift and capacity of the unit for treatment of produced fluids. An operational objective function is also formulated and its results are compared with the economic objective function, showing that the first can generate significant financial losses in the operation. The problem is solved by applying different optimization algorithms and a comparison of the results through a set of performance criteria is performed, showing that the method of sequential quadratic programming using a regularization function has the best performance, but its outcome is strongly influenced by the initial estimate provided. Aiming to ensure selection of the best initial estimate, we proposed a hybrid method that has shown excellent results.

Índice

Capítulo 1	1
Introdução	1
Capítulo 2	8
O Processo de Produção de Óleo e Gás	8
2.1. Processamento primário dos fluidos.....	8
2.2. <i>Gas Lift</i> Contínuo	16
Capítulo 3	20
Revisão Bibliográfica	20
3.1. Um Breve Histórico sobre a Otimização de <i>Gas Lift</i>	20
3.2. Fundamentos Teóricos sobre Técnicas de Otimização	23
Capítulo 4	38
Modelagem e Solução do Problema	38
4.1 Formulação do problema de otimização.....	38
4.2 Otimização da produção em cenário de queda de compressores	50
4.3 Otimização da produção considerando a pressão à montante da válvula <i>choke</i> dos poços	53
Capítulo 5	56
Resultados e Discussões	56
5.1 Cenário de estudo	56
5.2 Comparação entre a função objetivo econômica e a operacional.....	58
5.3 Comparação entre os resultados obtidos com o NLP e o MILP.....	62
5.4 Análise de sensibilidade à condição inicial do algoritmo SQP	65
5.5 Análise de sensibilidade dos métodos MILP em relação ao número de pontos da curva de eficiência	72

5.6 Algoritmo híbrido para solução do problema de otimização da produção de poços que operam com <i>gas lift</i> contínuo	75
5.7 Otimização da produção em cenário de queda de compressores	79
5.8 Otimização da produção considerando a pressão à montante da válvula <i>choke</i> dos poços	81
5.9 Análise de Incerteza	84
Capítulo 6	93
Conclusões e Sugestões para Trabalhos Futuros	93
Referências Bibliográficas	95

Lista de Figuras

Figura 1.1 – Pirâmide do processo de tomada de decisão.....	2
Figura 1.2 - Etapas do processo de otimização da produção.....	5
Figura 1.3 - Ganhos quantitativos da otimização (Fonte: CERA).....	7
Figura 2.1 – Diagrama esquemático da planta de processamento primário de uma plataforma de produção (Fonte: Reider, C. A.).....	9
Figura 2.2 – Esquema simplificado de um separador horizontal bifásico.....	11
Figura 2.3 - Distribuição da produção de óleo por método de elevação (Fonte: Petrobras).....	18
Figura 2.4 – Perda de carga na coluna de produção como função da vazão de <i>gas lift</i> .	19
Figura 3.1 – Diferença entre mínimo local e global.....	25
Figura 3.2 – Método clássico.....	31
Figura 3.3 – Método das estruturas especiais.....	32
Figura 3.4 – Método da segmentação linear.....	33
Figura 4.1 – Curvas de eficiência de <i>gas lift</i> : (A) poço surgente e (B) poço com vazão de ativação.....	43
Figura 4.2 – Resultados do ajuste de uma função polinomial de segundo grau e da função proposta por Alarcón <i>et al.</i> (2002) ao conjunto de pontos de um poço.....	44
Figura 4.3 – Resultado do ajuste de uma curva com a adição de uma função de regularização para modelar um poço do tipo B.....	45
Figura 4.4 – Cenário de queda de compressores com aumento da queima para o <i>flare</i> .	51
Figura 4.5 – Superfície representando a produção de óleo de um poço como função da pressão na cabeça do poço e da vazão de <i>gas lift</i>	54
Figura 5.1 – Curvas de eficiência de <i>gas lift</i> dos 12 poços produtores.	56

Figura 5.2 – Gráfico da diferença entre os resultados da função objetivo econômica e operacional para diferentes valores de D_w e D_o	61
Figura 5.3 – Gráfico da diferença entre os resultados da função objetivo econômica e operacional para diferentes valores de D_{ig} e D_o	62
Figura 5.4 – Gráfico da diferença entre os resultados da função objetivo econômica e operacional para diferentes valores de D_{oc} e D_o	62
Figura 5.5 – Análise de concavidade da curva de eficiência.....	66
Figura 5.6 – Fluxograma da metodologia utilizada para analisar a sensibilidade do SQP à estimativa inicial.	67
Figura 5.7 – Distribuição da estimativa inicial em função do cenário para quatro poços do caso de estudo.....	67
Figura 5.8 – Distribuição da vazão de óleo como função do cenário de estudo.	68
Figura 5.9 – Histograma da vazão total de óleo.	69
Figura 5.10 – Distribuição da vazão total de <i>gas lift</i> como função do cenário.	69
Figura 5.11 – Histograma da vazão de <i>gas lift</i> total.	70
Figura 5.12 – Distribuição do tempo de CPU como função do cenário.....	71
Figura 5.13 – Distribuição do número de iterações como função do cenário.	71
Figura 5.14 – Gráfico do tempo de CPU como função do número de iterações.	72
Figura 5.15 – Vazão total de óleo e de <i>gas lift</i> como função do número de pontos utilizados para representar a curva de eficiência.	73
Figura 5.16 – Tempo de CPU e número de iterações como função do número de pontos utilizados para representar a curva de eficiência.	74
Figura 5.17 – Tempo de CPU como função do número de iterações.....	74
Figura 5.18 – Esquema do algoritmo híbrido proposto.....	76
Figura 5.19 – Vazão total de óleo como função da capacidade de compressão da plataforma.....	77
Figura 5.20 – Vazão total de <i>Gas Lift</i> como função da capacidade de compressão da plataforma.....	78

Figura 5.21 – Tempo de CPU como função da capacidade de compressão da plataforma.	78
Figura 5.22 – Vazão total de óleo como função da queima de gás admissível para diferentes valores do fator de ponderação (Frente de Pareto).	80
Figura 5.23 – Queima como função da capacidade de compressão e do fator de ponderação.....	80
Figura 5.24 – Vazão total de óleo como função da capacidade de compressão e do fator de ponderação.	81
Figura 5.25 – Vazão total de óleo como função da capacidade de tratamento de água.	82
Figura 5.26 – Vazão de <i>gas lift</i> de cada poço como função da capacidade de tratamento de água.....	83
Figura 5.27 – Vazão de óleo de cada poço como função da capacidade de tratamento de água.....	83
Figura 5.28 – Pressão a montante do <i>choke</i> de cada poço como função da capacidade de tratamento de água.....	84
Figura 5.29 – Vazão total de líquido como função da capacidade de tratamento de água.	84
Figura 5.30 – Fluxograma do procedimento de análise de incerteza.	85
Figura 5.31 – Histograma do BSW do Poço 1.	87
Figura 5.32 – Histograma do BSW do Poço 2.	87
Figura 5.33 – Histograma do BSW do Poço 3.	88
Figura 5.34 – Histograma do BSW do Poço 4.	88
Figura 5.35 – Histograma do BSW do Poço 5.	89
Figura 5.36 – Histograma do BSW do Poço 6.	89
Figura 5.37 – Histograma da produção total de óleo da plataforma.....	90
Figura 5.38 – Histograma do consumo total de <i>gas lift</i> dos poços.....	90

Lista de Tabelas

Tabela 2.1 - Valores limites de concentração de óleo na água de descarte (Fonte: Arnold e Stewart, 2008).....	15
Tabela 3.1 – Principais linguagens de modelagem.	36
Tabela 3.2 – Principais <i>solvers</i> de otimização.....	36
Tabela 5.1 – Parâmetros dos poços produtores.	57
Tabela 5.2 – Preços e custos de referência adotados.....	57
Tabela 5.3 – Restrições operacionais da plataforma.	57
Tabela 5.4 – Resultados obtidos para diferentes valores do custo de tratamento de água e $Do = 70$ US\$/bbl.....	58
Tabela 5.5 – Resultados obtidos para diferentes valores de custo de tratamento de gás e $Do = 70$ US\$/bbl.....	59
Tabela 5.6 – Resultados obtidos para diferentes valores do custo de tratamento do óleo e $Do = 70$ US\$/bbl.....	59
Tabela 5.7 – Resultados obtidos para diferentes valores do custo de tratamento de água e $Do = 90$ US\$/bbl.....	59
Tabela 5.8– Resultados obtidos para diferentes valores de custo de tratamento de gás e $Do = 90$ US\$/bbl.....	59
Tabela 5.9 – Resultados obtidos para diferentes valores do custo de tratamento do óleo e $Do = 90$ US\$/bbl.....	59
Tabela 5.10 – Resultados obtidos para diferentes valores do custo de tratamento de água e $Do = 120$ US\$/bbl.....	60
Tabela 5.11 – Resultados obtidos para diferentes valores de custo de tratamento de gás e $Do = 120$ US\$/bbl.....	60
Tabela 5.12 – Resultados obtidos para diferentes valores do custo de tratamento do óleo e $Do = 120$ US\$/bbl.....	60

Tabela 5.13 – Relação entre as estratégias de otimização testadas e os modelos implementados.....	63
Tabela 5.14 – Resultados obtidos com os diferentes algoritmos de otimização testados.	64
Tabela 5.15 – Restrições operacionais impostas.	68
Tabela 5.16 – Restrições operacionais impostas.	73
Tabela 5.17 – Restrições operacionais impostas.	76
Tabela 5.18 – Restrições operacionais impostas.	79
Tabela 5.19 – Restrições operacionais impostas.	81
Tabela 5.20 – Restrições operacionais impostas.	86
Tabela 5.21 – Estatísticas do BSW dos poços.....	91
Tabela 5.22 – Estatísticas dos resultados da otimização.	91
Tabela 5.23 – Estatísticas da vazão de óleo produzida por poço.	92
Tabela 5.24 – Estatísticas do consumo de <i>gas lift</i> por poço.....	92

Nomenclatura

BSW: *Basic Sediments and Water* [%];

D_{ig} : Custo de compressão de uma unidade de gás [US\$/10³ft³];

D_o : Valor de uma unidade de óleo no mercado [US\$/bbl];

D_{oc} : Custo de tratamento de uma unidade de óleo produzido [US\$/bbl];

D_{pg} : Valor de uma unidade de gás no mercado [US\$/10³ft³];

D_w : Custo de tratamento de uma unidade de água produzida [US\$/bbl];

IP: Índice de Produtividade [m³/d/kgf/cm²];

N: Número de poços;

q_{gpj} : Vazão de gás produzida pelo poço *j* [Nm³/d];

q_{gtc} : A capacidade de compressão da plataforma [Nm³/d];

q_{igj} : Vazão de gás injetada no poço *j* [Nm³/d];

q_{igj}^{min} : Vazão injeção mínima do poço *j* [Nm³/d];

q_{igj}^{max} : Vazão injeção máxima do poço *j* [Nm³/d];

q_{ltc} : Capacidade de tratamento de líquido da plataforma [m³/d];

q_{oj} : Vazão de óleo produzida pelo poço *j* [m³/d];

q_o^{max} : Máxima produção de óleo [m³/d];

$queima^{max}$: Limite máximo de queima [Nm³/d];

q_{wj} : Vazão de água produzida pelo poço *j* [m³/d];

q_{wtc} : Capacidade de tratamento de água produzida da plataforma [m³/d];

RG0: Razão Gás-Óleo [m³/m³];

Capítulo 1

Introdução

A operação de uma plataforma de produção de óleo e gás envolve muitas decisões que são tomadas em diferentes níveis hierárquicos, caracterizados por diferentes escalas de tempo, que afetam o volume produzido e o custo operacional.

A Figura 1.1 exibe uma pirâmide contendo os diversos níveis de tomada de decisão envolvidos no processo de produção de uma plataforma, bem como a ordem de grandeza da escala de tempo envolvida em cada nível (Campos e Teixeira, 2011). As camadas mais baixas da pirâmide estão associadas aos processos de tomada de decisão que ocorrem a uma frequência maior, mas que são fortemente influenciados pelas informações ou direcionamentos fornecidos pelas camadas superiores.

A camada de controle regulatório é composta basicamente por controladores PID (proporcional-integral-derivativo) e tem como principal objetivo manter as variáveis do processo o mais próximo possível de um valor de referência (*setpoint*), reduzindo assim o efeito das perturbações (Campos e Teixeira, 2006; Nunes et al., 2010). Por ser uma função considerada crítica para a segurança do processo, o controle regulatório é executado no CLP (Controlador Lógico Programável).

O controle avançado tem como principais funções conduzir o processo para o ponto ótimo de operação determinado pela camada de otimização, reduzir a variabilidade do processo e evitar que o mesmo viole as suas restrições. O controlador preditivo multivariável é a estratégia de controle avançado mais utilizada pela indústria e os *setpoints* dos controladores PID são tipicamente as suas variáveis manipuladas (Zanin, 2001).

A camada de otimização em tempo real (RTO) é responsável por garantir a eficiência e rentabilidade da produção frente a variações nas condições de operação do processo tais como alterações na disponibilidade da planta e variações nas

características do fluido produzido. A otimização em tempo real opera de forma automática e a uma frequência que respeita a constante de tempo do processo. Sua principal função é garantir que a unidade esteja operando nas condições ótimas 7 dias por semana e 24 horas por dia.

Em geral, as camadas de controle avançado e otimização em tempo real são executadas por aplicativos instalados em um servidor dedicado na unidade de produção. A comunicação destas camadas com o controle regulatório ocorre através da rede de automação da plataforma.



Figura 1.1 – Pirâmide do processo de tomada de decisão.

A camada de planejamento da produção está vinculada a definição dos direcionadores de curto e médio prazo da produção a partir das informações fornecidas pela camada de planejamento estratégico e da análise dos dados de produção. Esta camada inclui o processo de otimização de curto prazo da produção que envolve decisões a serem tomadas pelos engenheiros com o objetivo de maximizar a produção e/ou reduzir o custo operacional.

Em processos onde a camada de otimização em tempo real não foi implementada, as decisões que a ela seriam atribuídas são tomadas pela camada de planejamento da produção, com o prejuízo de não se garantir a operação nas condições ótimas fora do horário administrativo. Por exemplo, caso ocorra a queda de um

compressor ou a parada não programa de um dos separadores da plataforma na sexta-feira a noite, o operador da plataforma teria que tomar a decisão baseada no seu conhecimento e experiência prévia, sendo que o engenheiro estaria disponível para executar a otimização apenas na segunda-feira pela manhã.

A camada de planejamento estratégico é responsável pela definição dos direcionadores de longo prazo baseados na análise de mercado e no plano de investimento da companhia.

Atualmente, apesar de já serem amplamente utilizadas em outros setores da indústria tais como o refino, as camadas de controle avançado e otimização em tempo real ainda estão em um estágio embrionário com respeito à aplicação em plataformas de produção de óleo e gás. Contudo, muitas empresas estão investindo em iniciativas para implantação e teste destas tecnologias em unidades marítimas de produção, o que é um indicativo de que em alguns anos elas poderão ser consideradas maduras pelo setor.

A otimização de curto prazo da produção, que é o foco deste trabalho, envolve o uso de modelos de simulação e de ferramentas de suporte a decisão baseadas na otimização matemática. As atividades desta camada são executadas pelos engenheiros que trabalham em terra dando suporte aos operadores da plataforma e contempla a definição do ponto ótimo de operação frente a restrições impostas pelo reservatório, poços, malha de escoamento e planta de processo da unidade. Dentre as variáveis de decisão consideradas neste processo estão às vazões de *gas lift*, as aberturas da válvula *choke* de produção e, em alguns casos, o alinhamento de poços.

As decisões operacionais tomadas pelos engenheiros de terra precisam ser validadas e, muitas vezes, executadas na planta pelos operadores, ou seja, eles são responsáveis por fechar a malha do processo de otimização da produção. Por isso, um dos fatores críticos para o sucesso do processo de otimização da produção é a existência de uma relação de confiança entre o operador embarcado e o engenheiro responsável pelo acompanhamento da plataforma.

Para que o processo de otimização da produção seja bem sucedido, ele deve se basear em um ciclo de cinco etapas (Bieker et al., 2007) que estão representadas na Figura 1.2 e descritas abaixo:

- ✓ Medição: onde as variáveis críticas do processo são medidas a uma taxa de amostragem e precisão adequadas.
- ✓ Validação de dados: o processo de tomada de decisões deve ser baseado em dados cuja qualidade foi garantida através da aplicação de técnicas de processamento de sinais e reconciliação de dados.
- ✓ Atualização dos modelos: os modelos de reservatório, poços, linhas e planta de processamento utilizados no processo de tomada de decisão devem representar da melhor forma possível o sistema real de produção. Para isto, eles devem ser atualizados a uma frequência adequada.
- ✓ Otimização matemática: os modelos atualizados devem ser utilizados em conjunto com uma ferramenta de suporte a decisão para garantir a obtenção das condições ótimas de operação respeitando as restrições imposta pelo reservatório, poços, linhas e planta de processo.
- ✓ Validação e execução: os resultados da otimização devem ser validados pelo engenheiro e operador e implementados na unidade para que se possam quantificar os benefícios.

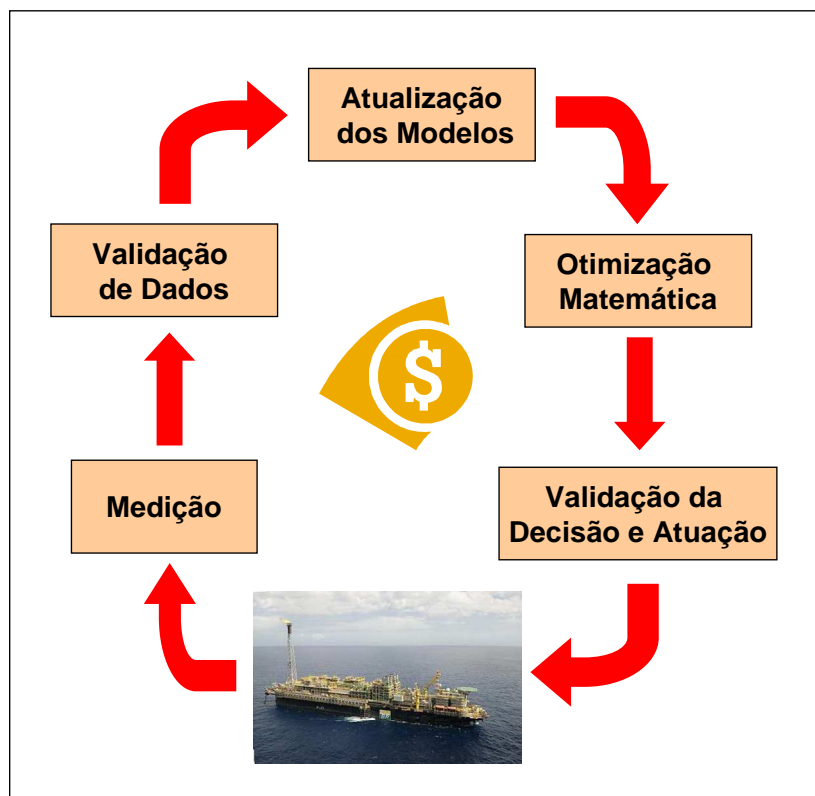


Figura 1.2 - Etapas do processo de otimização da produção.

O foco deste trabalho está no desenvolvimento de modelos matemáticos e estratégias de solução para a etapa de otimização matemática do ciclo acima descrito. A relação entre a otimização matemática e as outras etapas do ciclo são comentadas neste trabalho, porém, o desenvolvimento de algoritmos que facilitem a sua execução não faz parte do escopo.

O uso da otimização matemática como ferramenta de suporte a decisão tem como principais benefícios:

- ✓ Aumento de produção da ordem de 3 a 5%;
- ✓ Redução do custo operacional da ordem de 2 a 15%;
- ✓ Redução do tempo do processo de tomada de decisão;
- ✓ Aumento do número de alternativas avaliadas pelo engenheiro;

- ✓ Resposta rápida a situações inesperadas;
- ✓ Aumento da robustez e confiabilidade do processo de tomada de decisão.

Apesar de alguns dos benefícios acima listados serem qualitativos ou quantitativos difíceis de serem mensurados, muitas empresas e instituições de pesquisa têm tentado medir o ganho com o uso desta tecnologia, visando promover a sua disseminação na indústria.

A CERA (*Cambridge Energy Research Associates*) acompanhou iniciativas de diversas empresas do setor de óleo e gás com o objetivo de quantificar os benefícios do uso de algumas tecnologias, tais como a otimização da produção e estabeleceu limites superiores e inferiores para os ganhos de produção esperados com base no cenário de aplicação.

No gráfico da Figura 1.3, podem-se ver os resultados apresentados pela CERA, onde a linha tracejada indica o limite superior esperado para o ganho e a linha contínua o limite inferior. Os círculos cheios indicam ganhos reais das iniciativas de otimização da produção de empresas do setor de óleo e gás.

Os ganhos quantificados consideraram todas as etapas do ciclo de otimização da produção, bem como melhorias nos processos de trabalho dos engenheiros e operadores com o objetivo de garantir a sua execução.

Estes resultados comprovam a premissa de que a aplicação de ferramentas para auxiliar na otimização da produção em conjunto com um processo de trabalho bem definido pode trazer ganhos significativos para as empresas, justificando assim o investimento no desenvolvimento de soluções e na alteração do processo de trabalhos dos engenheiros e operadores.

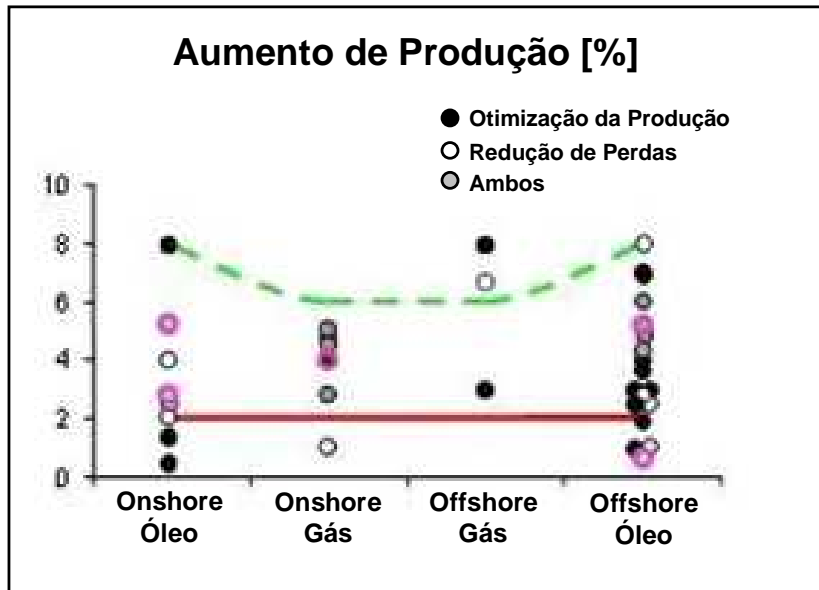


Figura 1.3 - Ganhos quantitativos da otimização (Fonte: CERA).

Esta dissertação está organizada em seis capítulos, sendo que o conteúdo de cada capítulo está detalhado abaixo.

O Capítulo 2 deste trabalho apresenta uma descrição da planta de processamento primário de uma plataforma de petróleo e os fundamentos do método de elevação artificial conhecido como *gas lift* contínuo.

O Capítulo 3 apresenta uma revisão bibliográfica sobre a otimização da produção de poços que operam com o auxílio do *gas lift* contínuo e uma breve revisão dos fundamentos teóricos da otimização matemática, focando principalmente nas técnicas utilizadas neste trabalho.

Os Capítulos 4 e 5 apresentam a modelagem proposta para o problema e os resultados obtidos com a solução do mesmo. Os resultados de uma análise de incertezas do problema de otimização também são apresentados.

O Capítulo 6 apresenta as conclusões do trabalho, bem como algumas sugestões para desenvolvimentos futuros.

Capítulo 2

O Processo de Produção de Óleo e Gás

2.1. Processamento primário dos fluidos

A função da planta de processamento de uma plataforma de produção é separar o fluido produzido pelos poços em três componentes, geralmente chamados de fases (óleo, gás e água) (Arnold e Stewart, 2008), e processar estas fases de modo a enquadrá-las nos requisitos para exportação (óleo e gás) e descarte (água).

O óleo, após ser condicionado, é transferido para terra através de oleodutos ou navios tanques, enquanto que o gás, após ser desidratado e comprimido, pode ser:

- ✓ Exportado para terra por gasodutos;
- ✓ Utilizado para geração de energia elétrica na plataforma;
- ✓ Utilizado para *gas lift*;
- ✓ Re-injetado no reservatório para manutenção da pressão do mesmo.

A água produzida, após ser tratada, pode ser descartada no mar ou re-injetada no reservatório para manutenção da pressão do mesmo.

Na Figura 2.1, pode-se ver um diagrama esquemático da planta de processamento primário de uma plataforma de petróleo.

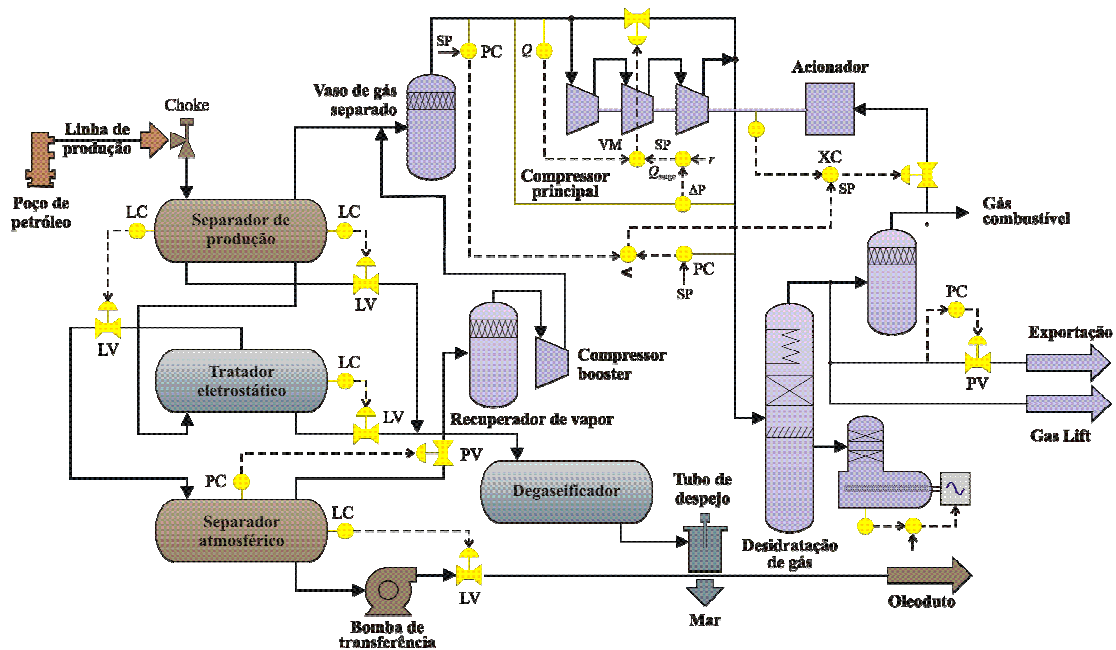


Figura 2.1 – Diagrama esquemático da planta de processamento primário de uma plataforma de produção (Fonte: Reider, C. A.).

2.1.1 Separação e tratamento do óleo

Inicialmente, os fluidos produzidos passam por separadores que podem ser classificados como horizontal ou vertical e bifásicos ou trifásicos a depender da sua posição e função.

No separador bifásico ocorre a separação do fluido produzido em duas fases (gás e líquido), enquanto que no separador trifásico ocorre a separação em três fases distintas (óleo, gás e água).

De modo geral, os separadores se baseiam nos seguintes mecanismos físicos para separar a fase líquida da fase gasosa (Thomas, 2001):

- ✓ Ação da gravidade e diferença de densidades, que são responsáveis pela decantação do elemento mais pesado no vaso;
- ✓ Separação inercial que se apresenta durante a ocorrência de mudanças bruscas de velocidade e direção de escoamento quando o fluido sofre um impacto, permitindo ao gás desprender-se da fase líquida devido à sua menor inércia;

- ✓ Aglutinação das partículas que ocorre através do contato das gotículas de óleo dispersas sobre uma superfície, o que facilita sua coalescência e posterior separação pela ação da gravidade;
- ✓ Ação da força centrífuga que aproveita as diferenças de densidade do óleo e do gás para atuar na separação.

Um separador típico pode ser dividido em quatro seções distintas que se caracterizam pela aplicação dos diferentes mecanismos físicos descritos acima para auxiliar no processo de separação (Verotti Filho, 2006):

- ✓ Seção de separação primária, onde o fluido se choca com defletores ou passa por um difusor que lhe impõe um movimento giratório fazendo com que o líquido se precipite para o fundo do vaso;
- ✓ Seção de acumulação de líquido que recebe e distribui o líquido coletado. Nesta seção também é feita a separação por ação da gravidade de bolhas gasosas que ficaram no seio da fase líquida após a separação primária. Para que esta separação seja efetiva, o óleo deve permanecer na seção durante um intervalo de tempo conhecido como tempo de retenção, que pode variar de 1 a 3 minutos em sistemas normais e chegar a 15 minutos em sistemas com formação de espuma;
- ✓ Seção de separação secundária que consiste em uma seção de decantação por ação da gravidade que é responsável pela separação das gotículas menores de óleo que foram carregadas com o gás, após a passagem pela seção primária;
- ✓ Seção aglutinadora, onde as gotículas de líquido arrastadas pela corrente de gás, e não separadas nas seções anteriores, são aglutinadas em meios porosos e recuperadas através da ação da gravidade. Os equipamentos utilizados nesta seção são também conhecidos como extratores de névoa.

A localização das diferentes seções de separação pode ser observada no esquema simplificado de separador horizontal bifásico da Figura 2.2.

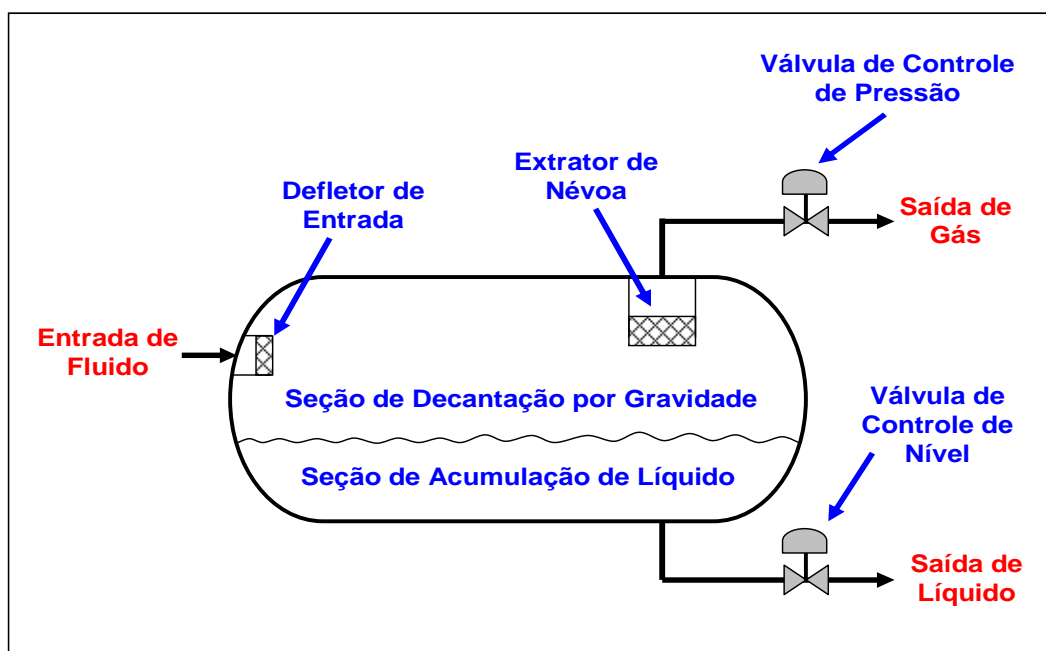


Figura 2.2 – Esquema simplificado de um separador horizontal bifásico.

Para maximizar a produção de óleo e obter uma fase de hidrocarboneto líquida mais estável (com menor tendência de evaporar-se), pode ser necessária a utilização de vários estágios de separação organizados em série e a pressões sucessivamente menores.

Neste processo, o fluido produzido é separado em líquido e gás por duas ou mais expansões (“flash”) a pressões sucessivamente menores, o que retém hidrocarbonetos leves que tenderiam a ficar na fase gasosa caso a separação fosse feita em apenas um estágio. Outro benefício deste processo é que a presença de hidrocarbonetos leves confere ao óleo recuperado uma menor densidade (maior grau API), e conseqüentemente um maior valor comercial.

Em geral, a definição do número de estágios de separação a ser utilizado é feita com base em uma análise do retorno financeiro obtido com o aumento da recuperação de óleo e do valor comercial do mesmo no mercado e com o aumento no investimento inicial a ser feito com a adição de um ou mais estágios de separação.

O tanque de armazenamento de óleo, quando existente, também é considerado como um estágio de separação.

Em alguns casos, a elevada produção dos poços ou a necessidade de processar fluidos com diferentes composições, torna necessária a existência de dois ou mais trens de separação operando em paralelo. Apesar do maior peso e área demandado por este tipo de arranjo, o que não é bem visto em se tratando de unidades marítimas de produção, o mesmo tem o benefício de garantir uma maior flexibilidade operacional, pois permite que o operador altere o alinhamento dos poços entre os dois trens de separação a depender da necessidade. Outra vantagem é a maior robustez da planta, pois este arranjo garante a continuidade operacional após a ocorrência de uma falha em um dos trens de separação.

No processo de produção de petróleo, um dos contaminantes mais indesejados e abundantes é a água, sendo que a sua quantidade produzida varia em função de diferentes fatores tais como as características do reservatório, a idade dos poços produtores e o método de recuperação utilizado (injeção de água ou vapor).

A água associada ao fluido produzido pode estar presente em três formas distintas (Souza Filho, 2006):

- ✓ Água livre: água escoando com o óleo, porém constituindo uma fase independente;
- ✓ Água emulsionada: água dispersa em gotículas muito pequenas na fase óleo, gerando uma emulsão água-óleo;
- ✓ Água dissolvida: pequena quantidade de água dissolvida no óleo.

Muitas plataformas possuem tratadores eletrostáticos a jusante dos separadores para retirar o excesso de água ainda existente (principalmente na forma de emulsão) e enquadrar o óleo em padrões de qualidade pré-estabelecidos para o refino.

Na Petrobras, o óleo deve possuir um BSW (*Basic Sediments and Water*) inferior a 1% em massa e uma concentração máxima de sais dissolvidos de 570 mg/L para ser enviado para a refinaria. O padrão adotado internacionalmente limita o BSW em 0,5% e a concentração de sais em 285 mg/L.

O tratador eletrostático separa a água emulsionada do óleo através da aplicação de um campo elétrico de alta voltagem à emulsão, fazendo com que as gotículas de água dispersas no óleo adquiram uma forma elíptica e se alinhem na direção do campo elétrico, com pólos induzidos de sinais contrários que criam uma força de atração que provoca a coalescência das gotículas. O campo elétrico contínuo provoca a coalescência por eletroforese e o campo elétrico alternado provoca a coalescência pelo mecanismo de dipolo induzido.

Após passar pelo tratador eletrostático, o óleo vai para um separador de baixa pressão conhecido como separador atmosférico e depois para o tanque ou para o oleoduto.

2.1.2 Tratamento e compressão do gás

O gás produzido, depois de ser separado, precisa ser desidratado e comprimido para ser exportado ou utilizado para *gas lift*.

A desidratação consiste na remoção do vapor d'água do gás que pode ser feita através dos processos de absorção ou adsorção (Arnold e Stewart, 1999). Ela é necessária para evitar a formação de hidratos nas linhas de *gas lift* e exportação.

Hidratos são sólidos muito semelhantes ao gelo, mas que se diferenciam deste por conter moléculas de gás aprisionadas entre as moléculas de água e por poder se apresentar no estado sólido mesmo a temperaturas superiores a 0°C. Para que ocorra a formação de hidratos é necessário que a água entre em contato com o gás a elevadas pressões e baixas temperaturas, o que é muito comum em campos de petróleo localizados em lâminas d'água profunda e ultra-profunda.

A absorção, que é o método comumente utilizado, é realizada em uma torre onde o gás flui em contracorrente a uma solução de glicol (monoetilenoglicol ou trietilenoglicol) que possui um grande poder higroscópico. O glicol saturado com água é regenerado, posteriormente, através de aquecimento, podendo retornar novamente ao processo.

A remoção através do processo de adsorção é feita com materiais que apresentam, dentre outras características, uma grande área superficial e elevada afinidade com a água. Dentre os materiais utilizados, pode-se citar a alumina, a sílica gel e as peneiras moleculares (alumino-silicatos de alguns metais). O adsorvente saturado é regenerado pela ação do calor (Verotti Filho, 2006).

Após desidratado, o gás é comprimido para ser exportado ou injetado nos poços de *gas lift*. Tipicamente, uma plataforma possui três compressores centrífugos operando em paralelo, sendo que cada compressor possui de dois a três estágios de compressão, a depender da plataforma.

Geralmente dois compressores operam continuamente, sendo que o terceiro fica em *stand-by* para o caso de uma eventual falha do sistema de compressão.

Devido à degradação com o tempo, os compressores podem ter a sua capacidade máxima reduzida, o que pode restringir significativamente a produção.

2.1.3 Tratamento e descarte da água produzida

A quantidade de água produzida associada com o óleo varia muito, podendo alcançar valores da ordem de 1% em volume no início da vida produtiva do poço e atingir valores próximos a 100% ao fim da sua vida econômica.

A água produzida possui uma salinidade elevada (3 a 4 vezes o teor de sais dissolvidos da água do mar) e sua composição pode variar significativamente de um reservatório para outro.

O tratamento da água tem por finalidade recuperar parte do óleo nela presente na forma de emulsão e condicioná-la para re-injeção no reservatório ou descarte no mar.

Conforme descrito na Seção 2.1.1, a água produzida é separada dos hidrocarbonetos através de equipamentos de processo tais como separadores trifásicos e tratadores eletrostáticos. Porém, estes equipamentos não conseguem separar totalmente os hidrocarbonetos da água produzida, sendo comum a presença de um volume de 0,1 a 10% de hidrocarbonetos na água após a separação.

As normas ambientais para descarte da água produzida no mar variam de país para país, sendo desenvolvidas e fiscalizadas por autoridades reguladoras ambientais governamentais.

A Tabela 2.1 lista alguns valores limites de concentração de óleo na água de descarte definidos pelas autoridades reguladoras ambientais de alguns países produtores de petróleo.

Tabela 2.1 - Valores limites de concentração de óleo na água de descarte (Fonte: Arnold e Stewart, 2008).

País	Concentração Limite
Equador, Colômbia e Brasil	30 mg/L
Argentina e Venezuela	15 mg/L
Indonésia	25 mg/L
Malásia e Oriente Médio	30 mg/L
Nigéria, Angola, Camarões e Costa do Marfim	50 mg/L
Mar do Norte e Austrália	30 mg/L
Tailândia	50 mg/L
EUA	29 mg/L

Outro indicador comumente utilizado pela indústria de petróleo para medir a qualidade da água para descarte é o TOG (teor de óleos e graxas). A Petrobras adota como limite para descarte no mar um TOG de 20 ppm.

Atualmente, os hidrociclones e a unidade de flotação são os equipamentos de separação óleo/água mais utilizados pela indústria de petróleo.

Os hidrociclones procuram recuperar os resíduos de óleo da água através da ação da força centrífuga que faz com que o fluido mais denso, ao entrar tangencialmente no

trecho de maior diâmetro do equipamento, fique em contato com as paredes do *liner* e siga em fluxo espiral em direção ao trecho de menor diâmetro, enquanto que o menos denso flui para o centro do *liner* formando um fluxo axial reverso, separando assim as duas fases líquidas. Os hidrociclones conseguem reduzir um TOG de até 1000 ppm para valores entre 100 e 200 ppm, a depender do projeto do equipamento.

A unidade de flotação procura recuperar os resíduos de óleo da água através da separação gravitacional. A eficiência da flotação depende principalmente da distribuição dos diâmetros das gotas de óleo e das condições operacionais. Quando operando em condições normais, ela consegue enquadrar o TOG no limite máximo de 20 ppm definido pelas normas ambientais.

A próxima seção irá apresentar os principais métodos de elevação artificial existentes e os critérios considerados no processo de escolha do método mais adequado para um determinado cenário. Por fim, o método de elevação artificial *gas lift* contínuo será apresentado em mais detalhes, visto que a otimização da produção de poços que operam com este método é o foco deste trabalho.

2.2. *Gas Lift* Contínuo

2.2.1. Métodos de elevação artificial

A maioria dos poços produtores de petróleo flui naturalmente para a superfície no primeiro estágio de sua vida produtiva, sendo chamados de poços surgentes.

Porém, quando o reservatório produtor de petróleo não possui pressão suficiente para transportar os fluidos produzidos para a superfície a uma vazão atrativa economicamente, diz-se que os poços produtores precisam do auxílio de um método de elevação artificial (Economides, et al., 1998; Golan e Whitson, 1986).

Existem muitos métodos de elevação artificial disponíveis, porém, a escolha do melhor método para um determinado poço ou campo produtor, depende de um conjunto de fatores, dentre os quais podemos citar (Thomas, 2001):

- ✓ Número de poços do campo;
- ✓ Diâmetro do revestimento;
- ✓ Produção de areia;
- ✓ Razão gás-líquido dos poços;
- ✓ Vazão;
- ✓ Profundidade do reservatório;
- ✓ Viscosidade dos fluidos;
- ✓ Disponibilidade de energia;
- ✓ Distância dos poços à plataforma de produção;
- ✓ Investimento necessário;
- ✓ Custo operacional.

Os métodos de elevação artificial mais utilizado atualmente na indústria de petróleo são:

- ✓ *Gas lift* contínuo;
- ✓ *Gas lift* intermitente;
- ✓ Bombeio Centrífugo Submerso (BCS);
- ✓ Bombeio Mecânico com Hastes (BM);

- ✓ Bombeio por Cavidades Progressivas (BCP).

Dentre os métodos de elevação artificial citados, apenas o *gas lift* contínuo e o bombeio centrífugo submerso são utilizados em unidades marítimas de produção.

De modo geral, cada método de elevação artificial possui vantagens e desvantagens que definem uma janela operacional na qual eles são mais eficientes quando comparados com os outros métodos.

2.2.2. *Gas Lift* Contínuo

Dentre os métodos de elevação artificial existentes, o *gas lift* contínuo é um dos mais utilizados por sua robustez, baixo custo e facilidade de manutenção.

Atualmente, cerca de 70% da produção de óleo no Brasil é oriunda de poços que produzem com o auxílio do *gas lift* contínuo, conforme pode ser visto no gráfico da Figura 2.3.




Figura 2.3 - Distribuição da produção de óleo por método de elevação (Fonte: Petrobras).

O *gas lift* contínuo aumenta a produção de óleo através da injeção contínua de gás comprimido na parte inferior da coluna de produção, utilizando-se para isto do espaço anular formado entre a coluna de produção e o tubo de revestimento e de uma válvula de orifício instalada na coluna (Takács, 2005). O gás injetado aumenta a produção de líquido através de dois mecanismos físicos:

- A energia de expansão do gás injetado que desloca o líquido para a superfície;
- A redução da massa específica do fluido produzido que faz com que a pressão do reservatório seja suficiente para deslocá-lo para superfície.

Porém, o aumento da vazão de injeção de gás aumenta as perdas de carga por atrito e aceleração, sendo que, a partir de certo momento, estas perdas superam os benefícios trazidos pela redução da massa específica do fluido e pela expansão do gás, provocando assim uma redução da produção de líquido. Este ponto de inversão caracteriza a máxima produção de óleo possível de ser obtida pela variação da vazão de injeção de gás. A influência da vazão de gas lift nas componentes da perda de carga (hidrostática e de aceleração e atrito) no poço e linhas pode ser vista no gráfico da Figura 2.4.




Figura 2.4 – Perda de carga na coluna de produção como função da vazão de *gas lift*.

Capítulo 3

Revisão Bibliográfica

3.1. Um Breve Histórico sobre a Otimização de *Gas Lift*

Ao longo do tempo, diversos pesquisadores estudaram o problema de otimização da produção de poços que produzem com o auxílio do *gas lift* contínuo propondo diferentes estratégias e algoritmos para a solução do problema.

Redden et al. (1974) propuseram em seu trabalho uma heurística para calcular a alocação ótima do *gas lift* em cenários onde não existem restrições de disponibilidade de gás e de tratamento dos fluidos produzidos. A heurística proposta consistia na conversão das curvas de eficiência de *gas lift* ($q_o \times q_{inj}$) dos poços para curvas de retorno econômico como função do custo de injeção do *gas lift*, seguida pela identificação, para cada poço, do ponto da curva com tangente igual a:

$$m = 1 + ROR/100$$

em que *ROR* é a taxa de retorno requerida definida pelo engenheiro em %. Os pontos identificados pelo algoritmo definem a condição ótima de operação dos poços. Para casos com restrição na disponibilidade de gás, os autores sugerem a redução sistemática da vazão de gás injetado em poços onde a curva de retorno econômico como função do custo de injeção é mais plana.

O trabalho de Kanu *et al.* (1981) foi o primeiro a utilizar o conceito da tangente econômica em cenários com e sem restrições na disponibilidade de gás para *gas lift*. O algoritmo proposto utiliza as curvas de eficiência de *gas lift* escritas para a vazão de líquido (óleo + água), ao invés da vazão de óleo produzido. A tangente econômica é calculada pela seguinte fórmula:

$$m = \frac{\Delta q_L}{\Delta q_g} = \frac{C_g}{f_o P}$$

em que C_g representa o custo do *gas lift*, f_o a fração de óleo produzida e P o preço do barril de petróleo no mercado internacional. Para o problema sem restrição de disponibilidade de gás, uma vez calculada a tangente econômica para cada poço, o ponto ótimo é obtido encontrando-se os pontos das curvas cujas tangentes equivalem à tangente econômica. Uma estratégia para considerar a restrição na disponibilidade de gás para *gas lift* também é apresentada neste trabalho.

Zheng-Gang *et al.* (1990) propuseram, em seu trabalho, modificações na estratégia proposta por Kanu *et al.* (1981) para considerar o custo de tratamento da água produzida no cálculo da tangente econômica e incluir restrições referentes à capacidade de tratamento de líquido (óleo + água produzida) da unidade.

Nishikiori (1989) propôs um algoritmo de otimização não-linear, baseado no método de Quasi-Newton, para maximizar a produção de óleo de um conjunto de poços, considerando apenas uma restrição na disponibilidade de gás para *gas lift*. O algoritmo foi codificado em Fortran e testado com três cenários distintos com cinco poços.

Lo (1992) propôs um modelo não-linear de otimização para maximizar a produção de óleo de um campo considerando como variáveis de decisão as vazões de *gas lift* dos poços e restrições nas capacidades de tratamento de líquido, óleo, água e na capacidade de compressão da unidade. Como cenário de teste foi utilizado um campo fictício com 20 poços. Para solucionar o problema, ele utilizou um algoritmo de otimização não-linear cujo nome não é citado no artigo.

Martínez *et al.* (1994) aplicaram um algoritmo genético para maximizar a produção de óleo considerando uma restrição na disponibilidade de gás para *gas lift*. Segundo os autores, o método conseguiu solucionar o problema de forma efetiva e eficiente. A estratégia foi testada em um cenário com 25 poços e obteve um resultado satisfatório em um tempo de CPU de 2 minutos rodando em um computador 386 de 33 MHz.

Buitrago et al. (1996) propuseram um algoritmo de busca que consiste na combinação de uma exploração estocástica do domínio do problema com uma heurística para cálculo da direção de subida com o objetivo de maximizar a produção de óleo considerando uma restrição na disponibilidade de gás para *gas lift*. De acordo com os autores, o método permite encontrar o ótimo global de forma eficiente e apresentou um menor consumo de gás quando comparado com os resultados do método da tangente econômica.

Alarcón *et al.* (2002) propuseram em seu trabalho uma estrutura de modelo que apresenta um melhor ajuste aos dados da curva de eficiência de *gas lift* gerados por simulação, quando comparado às estruturas usualmente utilizadas pela indústria de petróleo.

$$q_{oj}(q_{igj}) = c_1 + c_2 \cdot q_{igj} + c_3 \cdot q_{igj}^2 + c_4 \cdot \ln(q_{igj} + 1)$$

em que q_{oj} e q_{igj} são respectivamente as vazões de óleo e *gas lift* do poço j e c_1 , c_2 , c_3 e c_4 são parâmetros de ajuste do modelo.

Eles solucionaram o problema de maximização da produção de óleo considerando restrições na disponibilidade de gás para *gas lift* através do uso do algoritmo de programação quadrática seqüencial (SQP).

Wang et al. (2002) propuseram um modelo de otimização da produção de um conjunto de poços, cuja produção é misturada em um *manifold* localizado no campo e transportada para o separador através de um duto longo (aproximadamente 1200 metros de comprimento). A perda de carga nos poços e linhas foi calculada pelo modelo de *drift-flux* e as válvulas choke de produção foram modeladas pela correlação de Sachdeva et al. (1986).

A otimização tinha como objetivo maximizar a produção de óleo do campo respeitando as restrições impostas pelo reservatório, malha de escoamento e capacidade de tratamento de fluidos da planta de processamento. As variáveis de decisão incluíam as aberturas das válvulas *choke* de produção e a vazão de *gas lift* dos poços. O problema foi solucionado através do uso do algoritmo SQP.

Camponogara e Nakashima (2005) propuseram uma estratégia para solucionar o problema de otimização de *gas lift* baseada em um algoritmo de programação dinâmica.

Misener *et al.* (2009) resolveram o problema de maximização da produção de óleo considerando restrições na disponibilidade de gás para *gas lift* aplicando diferentes estratégias de linearização por partes ao modelo de otimização e o solucionando como um problema de programação linear inteira mista (MILP). Os métodos de linearização testados foram o método clássico (CM), o método da segmentação linear (LSM), o método da casca convexa (CHM) e o método das estruturas especiais (SSM). Todos os modelos testados foram solucionados através do uso do solver CPLEX.

Rashid *et al.* (2011) propuseram uma modelagem para o problema de otimização da produção de poços interligados em uma malha de escoamento complexa que operam com o auxílio do *gas lift* contínuo, considerando como variáveis de decisão a vazão de *gas lift* e a abertura do *choke* de produção, que é representada como uma variável discreta. A estratégia de solução proposta envolve o uso do simulador para geração de um conjunto de curvas que, devido à existência de descontinuidades, são modeladas por um conjunto de *splines*. A ativação das diferentes *splines* é feita com o uso de variáveis binárias e o problema resultante, que é de programação não-linear inteira mista (MINLP), foi resolvido com o uso do solver BONMIN.

A próxima seção irá apresentar os principais fundamentos teóricos sobre as técnicas de otimização utilizadas neste trabalho.

3.2. Fundamentos Teóricos sobre Técnicas de Otimização

De modo geral, os problemas de otimização podem ser divididos em famílias ou classes que são caracterizadas pela forma de sua função objetivo e de suas funções de restrição. Um método de solução para uma classe de problemas de otimização é um algoritmo que computa uma solução para o problema com uma precisão satisfatória.

Desde 1940, um grande esforço tem sido feito no desenvolvimento de algoritmos para solucionar as diversas classes de problemas de otimização existentes, analisando suas propriedades e implementando soluções eficientes (Boyd e

Vandenbergh, 2004).

A eficácia e eficiência destes algoritmos dependem de um conjunto de fatores tais como a classe a qual o problema pertence, o número de variáveis e restrições existentes, e a presença de estruturas especiais no modelo, tais como a ocorrência de esparsidade nas funções de restrição.

A otimização da produção de poços que operam com o auxílio do *gas lift* contínuo se enquadra na classe dos problemas de programação não-linear (NLP). Se considerarmos como variáveis de decisão, além da vazão de *gas lift*, a abertura e fechamento de poços e o alinhamento de poços para diferentes linhas, o problema passa a ser de programação não-linear inteira mista (MINLP).

Um problema de otimização é classificado como de programação não-linear (NLP) quando todas as suas variáveis de decisão são contínuas e quando a sua função objetivo ou as restrições são não-lineares. Esta classe de problemas pode ser representada da seguinte forma:

$$\min_{x \in \mathcal{R}^n} f(x)$$

Sujeito a:

$$h_i(x) = 0 \quad i = 1, 2, \dots, m$$

$$g_j(x) \leq 0 \quad j = 1, 2, \dots, r$$

A maioria dos algoritmos existentes para solução de problemas de programação não-linear (NLP) são algoritmos de busca local, ou seja, eles buscam um ponto no qual o valor da função objetivo é menor do que em todos os outros pontos factíveis localizados na sua vizinhança. Uma definição formal seria:

Um ponto x^* é um mínimo local se há uma vizinhança N de x^* tal que $f(x^*) \leq f(x)$ para todo $x \in N$.

Em geral, os algoritmos de otimização local são rápidos, podem solucionar problemas de grande escala e são amplamente aplicados na prática, por exigirem apenas

que a função objetivo e suas restrições sejam diferenciáveis.

Muitas vezes, a aplicação exige o cálculo do ótimo global, ou seja, do ponto pertencente à região factível do problema com o menor valor da função objetivo. Uma definição formal seria:

Um ponto x^* é um mínimo global se $f(x^*) \leq f(x)$ para todo x .

A complexidade de um problema de otimização global cresce exponencialmente com o tamanho do problema (definido pelo número de variáveis e restrições), sendo que, mesmo problemas pequenos (com dezenas de variáveis de decisão) podem demorar um longo período de tempo para serem solucionados.

Na prática, algoritmos para solução de problemas de otimização global geralmente são utilizados em problemas com poucas variáveis, elevado valor prático da solução ótima global e onde o tempo computacional não é crítico para a aplicação.

O gráfico de uma função complexa contendo múltiplos mínimos locais pode ser observado na Figura 3.1.

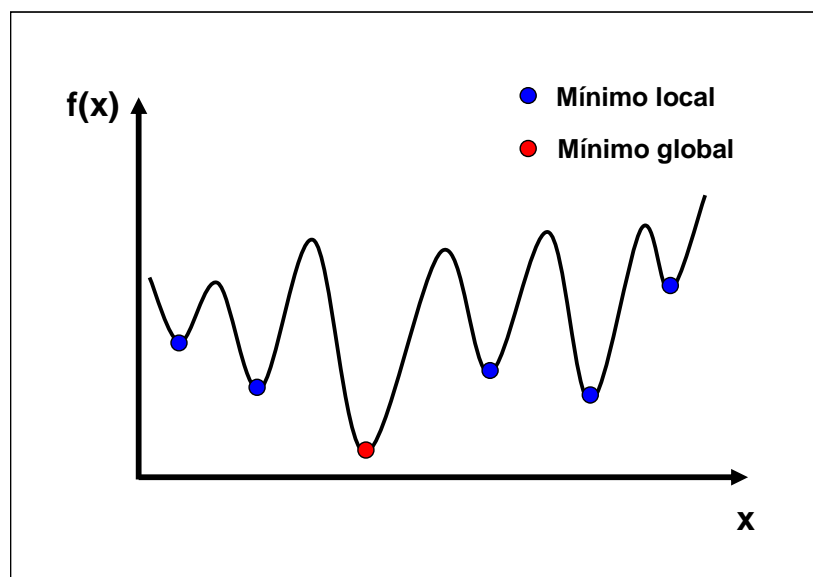


Figura 3.1 – Diferença entre mínimo local e global.

Uma propriedade importante de alguns problemas que pode ser explorada

durante a sua solução é o fato de que quando a função objetivo do mesmo é uma função convexa e as suas restrições formam uma região ou conjunto convexo, tem-se que todo ótimo local é também um ótimo global.

Um problema é classificado como de programação não-linear inteira mista (MINLP) quando envolve variáveis contínuas e inteiras, podendo ser representado da seguinte forma:

$$\min_{x \in \mathfrak{R}^n, y \in Z^p} f(x, y)$$

Sujeito a:

$$h_i(x, y) = 0 \quad i = 1, 2, \dots, m$$

$$g_j(x, y) \leq 0 \quad j = 1, 2, \dots, r$$

O acoplamento entre os domínios inteiro e contínuo associado com a presença de não-linearidades fazem com que os problemas de programação não-linear inteira mista (MINLP) sejam extremamente desafiadores do ponto de vista teórico, algorítmico e computacional (Floudas, 1995).

Algoritmos eficazes para solucionar problemas desta classe começaram a surgir apenas nas últimas duas décadas associados à melhoria da capacidade computacional.

Uma forma eficaz, embora aproximada, de solucionar problemas de programação não-linear inteira mista (MINLP) é através da aplicação de técnicas de linearização por partes que o transformam em um problema de programação linear inteira mista (MILP), que é uma classe de problemas de otimização para a qual existem algoritmos extremamente eficientes.

Como foi explicado nesta seção, existem diversos algoritmos e estratégias para solucionar problemas de programação não-linear (NLP), porém, este trabalho focará no uso do algoritmo de programação quadrática sequencial (SQP) e na aplicação de técnicas de linearização por partes seguida pelo uso de algoritmos para solução de problemas de programação linear inteira mista (MILP).

Nas próximas seções será apresentada uma descrição do algoritmo de programação quadrática seqüencial e das técnicas de linearização por partes, bem como um breve resumo sobre as técnicas de solução de problemas de programação linear inteira mista.

3.2.1. Algoritmo de Programação Quadrática Seqüencial (SQP)

O SQP é um dos algoritmos de otimização local mais popular para solução de problemas de programação não-linear (NLP), devido a sua rápida convergência e facilidade de adaptação para uma grande variedade de estruturas (Biegler, 2010).

A estratégia deste algoritmo consiste na solução de uma seqüência de aproximações de programação quadrática para o problema de programação não-linear. A vantagem desta estratégia está no fato de que ela se aproveita da existência de procedimentos eficientes para solucionar problemas de programação quadrática com convergência em um número reduzido de iterações, o que facilita a solução do problema não-linear (Edgar et al., 2001).

O método se baseia na solução das equações de Karush-Kuhn-Tucker (KKT), que são condições necessárias para otimalidade de um problema de otimização com restrição.

Dado o problema geral:

$$\min_{x \in K} f(x) \tag{3.1}$$

Sujeito a:

$$h_j(x) = 0 \tag{3.2}$$

$$g_j(x) \leq 0 \tag{3.3}$$

Escrevendo-se a função de Lagrange, temos:

$$L(x, \lambda, \mu) = f(x) + \lambda^T h(x) + \mu^T g(x) \tag{3.4}$$

O que nos leva ao seguinte conjunto de condições:

$$\nabla_x L(x, \lambda, \mu) = f(x) + \lambda^T \nabla h(x) + \mu^T \nabla g(x) = 0 \quad (3.5)$$

$$h(x) = 0 \quad (3.6)$$

$$g_j(x) = 0, \quad j \in \{\text{restrições ativas}\} \quad (3.7)$$

$$\mu \geq 0, \quad (3.8)$$

O que pode ser aproximado por sucessivos problemas de programação quadrática:

$$\min_{d \in \mathbb{R}^n} q(d) = \nabla^T f(x^k) d + \frac{1}{2} d^T H(x^k, \lambda^k, \mu^k) d \quad (3.9)$$

Sujeito a:

$$h(x^k) + \nabla^T h(x^k) d = 0 \quad (3.10)$$

$$g(x^k) + \nabla^T g(x^k) d \leq 0 \quad (3.11)$$

A matriz $H(x^k, \lambda^k, \mu^k)$ é uma aproximação positiva definida da matriz Hessiana da função de Lagrange. Este novo problema pode ser solucionado por qualquer algoritmo de programação quadrática. Para determinar a próxima iteração, usa-se a equação:

$$x_{k+1} = x_k + \alpha_k d_k \quad (3.12)$$

em que α_k é determinado por um procedimento de busca em linha apropriado.

Conforme foi explicado anteriormente, uma das técnicas para solução de problemas de programação não-linear (NLP) é através da aplicação de técnicas de linearização por partes que eliminam as não-linearidades do modelo transformando-o em um problema de programação linear inteira mista (MILP).

A próxima seção irá descrever as técnicas de linearização por partes mais utilizadas.

3.2.2. Linearização por Partes de Funções Não-Lineares

Formulações baseadas em modelos não-lineares podem ser evitadas através da

aplicação de técnicas de linearização por partes ao problema. Estas técnicas, usualmente, envolvem a inclusão de variáveis binárias ao modelo que o transformam em um problema de programação linear inteira mista (MILP), que tem como vantagem a existência de muitos algoritmos eficientes e robustos para solucioná-lo.

Quando o problema que se deseja resolver é de programação não-linear inteira mista (MINLP), a linearização por partes das funções não-lineares, quando possível de ser aplicada, é uma forma eficiente de solucionar o problema.

Já em situações onde o modelo é de programação não-linear, a inclusão de variáveis binárias pode tornar o problema mais complexo e demandar um maior número de iterações e tempo de CPU para obter uma solução que atenda aos requisitos do problema.

As técnicas de linearização por partes aproximam a função não-linear que modela o sistema por segmentos de reta, sendo que a forma com a qual é feita esta aproximação é o que diferencia os métodos existentes. A qualidade da aproximação está diretamente relacionada com o número de segmentos de reta utilizados para representar a função não-linear, porém, quando maior o número de segmentos maior é o tempo para solução do problema.

O método clássico (CM) realiza a linearização por partes através da introdução de uma variável contínua $\lambda \in [0,1]$ que serve como um peso para a combinação convexa e uma variável binária $y \in \{0,1\}$ que restringe a posição dos pesos com valor diferente de zero (Floudas, 1995). Apenas dois pesos adjacentes podem assumir valores diferentes de zero.

As equações abaixo representam o modelo clássico, sendo que os pontos (x_i, z_i) representam a função não-linear, ilustrada na Figura 3.2.

$$x = \sum_{i=1}^n \lambda_i x_i \tag{3.13}$$

$$z = f(x) = \sum_{i=1}^n \lambda_i z_i$$

$$(3.14)$$

$$\lambda_i \geq 0 \quad (3.15)$$

$$\sum_{i=1}^n \lambda_i = 1 \quad (3.16)$$

$$\sum_{i=1}^n y_i = 1 \quad (3.17)$$

$$\lambda_0 \leq y_1 \quad (3.18)$$

$$\lambda_i \leq y_i + y_{i+1} \quad (3.19)$$

$$\lambda_n \leq y_n \quad (3.20)$$

As equações (3.13) e (3.14) representam as variáveis x e $f(x)$ como uma função da combinação convexa dos pontos (x_i, z_i) ponderados pelo peso λ_i . Já as equações (3.15) e (3.16) tem como objetivo garantir que os pesos são positivos e seus somatórios iguais a 1. A equação (3.17) faz com que apenas um segmento de reta esteja ativo por vez, enquanto que as equações (3.18) a (3.20) impõe que apenas pesos adjacentes podem ser diferentes de zero.

Uma representação gráfica do processo de linearização por partes pode ser vista na Figura 3.2.




Figura 3.2 – Método clássico.

O método das estruturas especiais (SSM) reconhece, sem precisar utilizar as variáveis binárias (y_i), o fato de que quaisquer dois lambdas, para serem diferentes de zero, devem ser consecutivos. Isto é feito através da declaração dos pesos λ_i como uma variável do tipo SOS2 (*Special Ordered Set 2*), que é uma estrutura reconhecida pela maioria dos pacotes computacionais de otimização e que estipula que no máximo dois lambdas podem ser positivos e, se positivos, devem ser consecutivos, eliminando assim a necessidade de inclusão das variáveis binárias (Keha et al., 2002).

As equações abaixo representam o modelo das estruturas especiais. A única diferença deste modelo para o modelo clássico é a ausência das variáveis binárias e a declaração dos pesos como variáveis do tipo SOS2.

$$x = \sum_{i=1}^n \lambda_i x_i \quad (3.21)$$

$$z = f(x) = \sum_{i=1}^n \lambda_i z_i \quad (3.22)$$

$$\lambda_i \geq 0 \quad (3.23)$$

$$\sum_{i=1}^n \lambda_i = 1$$

(3.24)

$$\lambda_i \in SOS2$$

(3.25)

Uma representação gráfica do processo de linearização por partes utilizando o modelo das estruturas especiais pode ser vista na Figura 3.3.




Figura 3.3 – Método das estruturas especiais.

O método de segmentação linear (LSM) utiliza as variáveis binárias $y \in \{0,1\}$ para definir o segmento de reta ativo, à semelhança do método clássico, e representa as funções não-lineares como um somatório de funções lineares, utilizando os coeficientes β e α .

As equações abaixo representam o método da segmentação linear.

$$X = \sum_{i=1}^{n-1} X_i \tag{3.26}$$

$$z = f(X) = \sum_{i=1}^{n-1} (\alpha_i y_i + \beta_i X_i) \tag{3.27}$$

$$\beta_i = \frac{z_{i+1} - z_i}{x_{i+1} - x_i} \quad (3.28)$$

$$\alpha_i = z_i - \beta_i x_i \quad (3.29)$$

$$x_i y_i \leq X_i \leq x_{i+1} y_i \quad i = 1, 2, \dots, (n-1) \quad (3.30)$$

$$\sum_{i=1}^n y_i = 1 \quad (3.31)$$

Uma representação gráfica do processo de linearização por partes utilizando o método da segmentação linear pode ser vista na Figura 3.4.




Figura 3.4 – Método da segmentação linear.

Uma vez que o problema não-linear (NLP) é transformado em um problema de programação linear inteira mista (MILP) através da aplicação de técnicas de linearização por partes é necessário utilizar um algoritmo de otimização aplicado a esta classe de problemas para solucioná-lo.

A próxima seção deste trabalho irá listar os principais algoritmos existentes para solução desta classe de problemas.

3.2.3. Técnicas para Solução de Problemas de Programação Linear Inteira Mista (MILP)

Um grande número de problemas de otimização possui variáveis contínuas e inteiras que aparecem combinadas linearmente na sua função objetivo e restrições. Eles são classificados como problemas de programação linear inteira mista (MILP) e aparecem com frequência em aplicações relacionadas com a operação, projeto e locação de plantas de processo.

Esta classe de problemas de otimização pode ser representada da seguinte forma:

$$\min_{x \in R^n, y \in Z^q} c^T x + d^T y$$

Sujeito a:

$$Ax + By \leq b$$

em que:

x : vetor de n variáveis contínuas;

y : vetor de q variáveis inteiras;

c, d : vetores de parâmetros com dimensão $(n \times 1)$ e $(q \times 1)$, respectivamente;

A, B : matrizes de dimensão apropriada;

b : vetor de p desigualdades.

A maior dificuldade que aparece em problemas de programação linear inteira mista é oriunda da natureza combinatorial das variáveis inteiras. Qualquer escolha para os elementos do vetor y resultam em um problema de programação linear (LP) que pode ser facilmente resolvido.

Com base no que foi explicado acima, conclui-se que uma forma de resolver um problema de programação linear inteira mista seria através da força bruta, na qual se enumeram todas as possíveis combinações das variáveis inteiras e se resolve o problema para todas as combinações, comparando os resultados para identificar o que apresentasse o menor valor da função objetivo. Infelizmente, o esforço computacional cresce exponencialmente como função do número de variáveis inteiras, o que torna esta

estratégia inviável para problemas de médio a grande porte.

Com o objetivo de solucionar o problema de programação linear inteira mista de forma eficiente, muitos algoritmos foram propostos desde o início da década de 60, sendo que abaixo estão listados os principais algoritmos.

Métodos de *Branch and Bound*: Esta classe de métodos emprega uma árvore de busca para representar as possíveis combinações das variáveis inteiras, divide sistematicamente a região factível do problema em subdomínios e gera limites superiores e inferiores válidos em diferentes níveis da árvore de busca. O objetivo do algoritmo é gradualmente obter melhores valores para os limites superiores e inferiores e terminar a execução quando o *gap* entre o limite superior e inferior for menor do que um valor pré-estabelecido.

Os métodos de *branch and bound* têm apresentado excelentes resultados e, atualmente, são os mais utilizados para solucionar problemas práticos (Gunnerud, 2011).

Métodos dos planos de corte: nestes métodos, novas restrições chamadas de cortes são criadas sistematicamente com o objetivo de reduzir a região factível do problema até que uma solução inteira ótima seja obtida.

Métodos de decomposição: nestes métodos, a estrutura matemática do modelo é explorada através do particionamento de variáveis, dualidade e métodos de relaxação.

Neste trabalho, utilizou-se um *solver* de otimização baseado no algoritmo de *branch and bound* para solucionar o problema de programação linear inteira mista.

A próxima seção irá descrever alguma das principais linguagens de modelagem de problemas de otimização existentes, bem como os *solvers* mais utilizados.

3.2.4 Linguagens e *solvers* para modelagem e solução de problemas de otimização

Tradicionalmente, os problemas de otimização eram modelados em linguagens de programação convencionais, tais como Fortran, C e C++, e solucionados através do

uso de bibliotecas de *solvers* disponíveis para estas linguagens.

Atualmente, existem muitas linguagens desenvolvidas especificamente para modelagem de problemas de otimização.

A principal vantagem destas linguagens está na similaridade existente entre a sintaxe por elas adotada e a notação matemática tradicionalmente utilizada para representar um problema de otimização, o que faz com que mesmo uma pessoa com poucos conhecimentos de programação possa modelar e solucionar um problema real.

Outra vantagem está na flexibilidade que elas oferecem, permitindo que diversos problemas distintos sejam rapidamente modelados e solucionados.

Na Tabela 3.1, pode-se ver uma lista das linguagens de modelagem de problemas de otimização mais utilizadas na indústria e no meio acadêmico.

Tabela 3.1 – Principais linguagens de modelagem.

Abreviação	Significado
GAMS	<i>General Algebraic Modeling System</i>
AMPL	<i>A Mathematical Programming Language</i>
AIMMS	<i>Advanced Integrated Multidimensional Modeling Software</i>
MOSEL	-

Para permitir a solução de problemas de otimização de diferentes classes, estas linguagens possuem integração com um conjunto de *solvers* que podem ser facilmente utilizados. Na Tabela 3.2, pode-se ver uma lista com os principais *solvers* de otimização disponíveis, bem como a classe de problemas a qual eles podem ser aplicados.

Tabela 3.2 – Principais *solvers* de otimização.

Solvers de Otimização	Classes de Problemas
CPLEX	LP, QCP, MIP e MIQCP
CONOPT	NLP
BARON	MINLP e NLP
KNITRO	NLP
SNOPT	NLP
XPRESS	LP, QCP e MIP
MINOS	NLP
BONMIN	MINLP

Neste trabalho, o problema de otimização da produção de poços que operam com o auxílio do *gas lift* contínuo foi modelado com o uso do software GAMS e solucionado com a aplicação dos *solvers* SNOPT e CPLEX, conforme será apresentado nos Capítulos 4 e 5.

Capítulo 4

Modelagem e Solução do Problema

4.1 Formulação do problema de otimização

4.1.1 Função objetivo

O problema de otimização da produção de uma plataforma pode ser modelado de duas formas distintas: uma utilizando uma função objetivo econômica com a qual se pretende maximizar o lucro obtido com a operação e outra adotando uma função objetivo operacional com a qual se pretende maximizar a produção de óleo do campo.

Tradicionalmente, em otimizações de curto prazo (com um horizonte de tempo de horas a dias), a indústria tem adotado com frequência a função objetivo operacional, partindo-se da premissa de que, devido ao elevado valor do óleo no mercado internacional, a sua máxima produção sempre irá gerar o máximo retorno econômico. Outro fator que justifica esta escolha é a dificuldade de se obter os custos unitários para tratamento dos fluidos produzidos. Estes custos variam de uma plataforma para outra em valor e método de cálculo, sendo função da complexidade do processo de produção da unidade.

A equação (4.1) representa a função objetivo econômica, enquanto que a equação (4.2) a função objetivo operacional.

$$Z = \sum_{j=1}^N [D_o \cdot q_{oj} + D_{pg} \cdot q_{gpj} - D_w \cdot q_{wj} - D_{ig} \cdot (q_{igj} + q_{gpj}) - D_{oc} \cdot q_{oj}] \quad (4.1)$$

$$Z = \sum_{j=1}^N [q_{oj}] \quad (4.2)$$

em que

D_o : Valor de uma unidade de óleo no mercado;

D_{pg} : Valor de uma unidade de gás no mercado;
 D_w : Custo de tratamento de uma unidade de água produzida;
 D_{ig} : Custo de compressão de uma unidade de gás;
 D_{oc} : Custo de tratamento de uma unidade de óleo produzido;
 N : Número de poços;
 q_{oj} : Vazão de óleo produzida pelo poço j ;
 q_{gpj} : Vazão de gás produzida pelo poço j ;
 q_{wj} : Vazão de água produzida pelo poço j ;
 q_{igj} : Vazão de gás injetada no poço j .

Como a otimização em questão é de curto prazo, na função objetivo econômica considerou-se apenas os custos operacionais que variam com a produção. Para uma análise econômica mais detalhada do processo de produção, visando decisões de médio a longo prazo (perfuração de novos poços, aumento da capacidade da plataforma, etc.), recomenda-se a inclusão dos custos fixos, investimentos e a depreciação do capital com o tempo.

A próxima seção irá descrever as principais restrições operacionais presentes em uma plataforma de produção de óleo e gás.

4.1.2 Restrições operacionais

Conforme detalhado no Capítulo 2, uma plataforma é composta por um conjunto de equipamentos que tem como função separar os fluidos produzidos e enquadrá-los em certos requisitos para exportação e descarte.

Estes equipamentos possuem limitações operacionais estabelecidas na fase de projeto ou oriundas da degradação dos mesmos com o tempo.

A ocorrência de paradas não programadas de equipamentos críticos da plataforma também podem submeter o processo de produção de óleo e gás a restrições severas que devem ser consideradas durante a otimização.

Um dos equipamentos mais importantes de uma plataforma é o compressor que comprime o gás para exportação e *gas lift*. A capacidade de compressão de uma plataforma pode ser representada pela restrição dada pela equação (4.3).

$$\sum_{j=1}^N [q_{gpj} + q_{igj}] \leq q_{gtc} \quad (4.3)$$

em que q_{gtc} é a capacidade de compressão da plataforma.

Muitas vezes, os poços apresentam características operacionais específicas que requerem uma limitação na sua vazão de injeção de *gas lift*. Esta limitação pode ser proveniente da ocorrência de instabilidades dinâmicas a baixas vazões de *gas lift*, que não podem ser representadas por um modelo de regime permanente, ou do uso do *gas lift* para injeção de produtos químicos no poço, o que demanda uma vazão mínima para ser executada. Estes cenários podem ser representados com a inclusão da restrição dada pela equação (4.4) no modelo.

$$q_{igj}^{\min} \leq q_{igj} \leq q_{igj}^{\max} \quad (4.4)$$

em que q_{igj}^{\min} é a vazão injeção mínima do poço j e q_{igj}^{\max} é a vazão injeção máxima do poço j .

Em alguns casos, o engenheiro responsável pela otimização da produção precisa definir a disponibilidade de gás para *gas lift*. Nestes casos, a soma das vazões de injeção de cada poço não deve ser superior à disponibilidade de gás para *gas lift*, conforme pode ser visto na restrição expressa pela equação (4.5).

$$\sum_{j=1}^N q_{igj} \leq q_{igt} \quad (4.5)$$

Para separar o fluido produzido em três diferentes fases (óleo, gás e água) e enquadrar o óleo nos requisitos de qualidade estabelecidos para exportação (por oleoduto ou navio tanque), existe um conjunto de separadores conectados em série,

sendo que a menor capacidade de tratamento de líquido destes separadores restringe a produção dos poços. Esta limitação é representada pela restrição dada pela equação (4.6).

$$\sum_{j=1}^N [q_{oj} + q_{wj}] \leq q_{ltc} \quad (4.6)$$

em que q_{ltc} é a capacidade de tratamento de líquido da plataforma.

A água produzida, depois de separada do óleo, deve ser enquadrada nos requisitos para descarte, o que é feito por um conjunto de equipamentos que contempla hidrociclones e flotadores. Esta limitação é representada pela restrição dada pela equação (4.7).

$$\sum_{j=1}^N q_{wj} \leq q_{wtc} \quad (4.7)$$

em que q_{wtc} é a capacidade de tratamento de água produzida da plataforma.

4.1.3 Cálculo das vazões de gás e água produzidas

Durante o teste de produção de um poço, que geralmente ocorre uma vez por mês, as vazões de óleo, gás e água produzidas são medidas em uma determinada condição operacional.

Estas vazões são utilizadas para calcular dois parâmetros que caracterizam o poço produtor e são conhecidos como BSW (*Basic Sediments and Water*), calculado pela equação (4.8), e RGO (Razão gás-óleo) que é calculado pela equação (4.9).

$$BSW = \frac{q_w}{q_w + q_o} \cdot 100 \quad (4.8)$$

$$RGO = \frac{q_{gp}}{q_o} \quad (4.9)$$

Em geral, pode-se dizer que o BSW e o RGO variam muito lentamente e de forma independente da condição de operação, exceto em cenários especiais onde ocorrem fenômenos tais como a formação de cone de gás e/ou de água, problemas de cimentação, etc. Sendo assim, considerando-se como conhecidos o RGO e BSW de um poço e dada uma vazão de óleo do mesmo é possível calcular as vazões de gás e água produzidos utilizando as equações (4.10) e (4.11).

$$q_{wj} = \frac{BSW}{100 - BSW} \cdot q_{oj} \quad (4.10)$$

$$q_{gpj} = RGO \cdot q_{oj} \quad (4.11)$$

4.1.4 Curvas de eficiência de *gas lift*

O conjunto de pontos que compõe as curvas de eficiência de *gas lift* é calculado através do uso de simuladores de escoamento multifásico em regime permanente.

Os modelos existentes nestes simuladores representam as propriedades dos fluidos produzidos, bem como as características geométricas e condições operacionais do poço e das linhas submarinas.

Os dados medidos durante o teste de produção (vazões de óleo, gás e água produzidas), em conjunto com algumas informações medidas continuamente no poço (pressões, temperaturas e vazão de gás para *gas lift*), são utilizados para o ajuste do modelo.

Uma vez ajustado, o modelo passa a ser utilizado para prever a vazão de óleo em condições operacionais distintas das existentes durante o período de teste.

As curvas de eficiência de *gas lift* são utilizadas para relacionar a vazão de óleo ou líquido produzida com a vazão de injeção de gás, que são as variáveis de decisão do problema de otimização.

Elas podem apresentar formas distintas a depender das características do poço,

conforme pode ser visto na Figura 4.1.

A curva A da Figura 4.1 exemplifica o comportamento de um poço surgente, ou seja, que não depende do uso de *gas lift* para produzir. Neste caso, a injeção de gás é utilizada para fazer com que o poço produza a uma vazão mais atrativa economicamente.

Já a curva B, representa um poço que depende de uma vazão de injeção mínima de gás (também chamada de vazão de ativação) para começar a produzir, o que aparece como uma descontinuidade na curva.

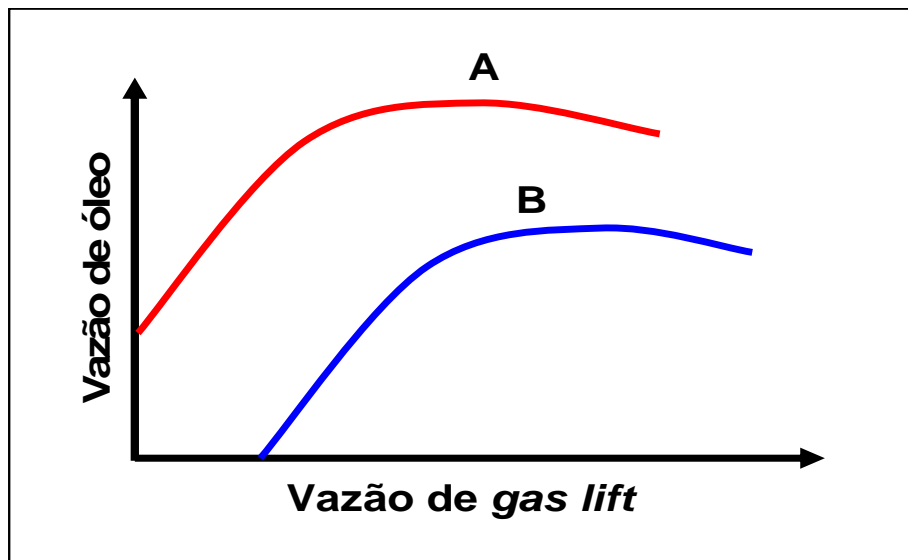


Figura 4.1 – Curvas de eficiência de *gas lift*: (A) poço surgente e (B) poço com vazão de ativação.

Para utilizá-las na formulação de um problema de otimização não-linear (NLP) é necessário ajustar uma curva ao conjunto de pontos gerados por simulação, o que é feito através da aplicação do método dos mínimos quadrados.

Tradicionalmente, utiliza-se um polinômio do segundo grau, equação (4.12), ou terceiro grau para ajustar o conjunto de pontos. Porém, Alarcón *et al.* (2002) apresentaram em seu trabalho uma função, expressa pela equação (4.13), que resulta em um melhor ajuste, conforme foi citado na Seção 3.1 deste trabalho.

$$q_{oj}(q_{igj}) = c_1 + c_2 \cdot q_{igj} + c_3 \cdot q_{igj}^2 \quad (4.12)$$

$$q_{oj}(q_{igj}) = c_1 + c_2 \cdot q_{igj} + c_3 \cdot q_{igj}^2 + c_4 \cdot \ln(q_{igj} + 1) \quad (4.13)$$

em que c_1 , c_2 , c_3 e c_4 são parâmetros dos modelos.

Os resultados do ajuste das curvas representadas pelas equações (4.12) e (4.13) ao conjunto de pontos de um poço modelado neste trabalho podem ser vistos na Figura 4.2.




Figura 4.2 – Resultados do ajuste de uma função polinomial de segundo grau e da função proposta por Alarcón *et al.* (2002) ao conjunto de pontos de um poço.

Quando o poço em questão é do tipo A, o procedimento de ajuste descrito acima é suficiente, porém, quando o poço é do tipo B é necessário modificar a equação (4.13) para que ela represente o trecho onde ocorre a descontinuidade. Neste trabalho, propõe-se a inclusão de uma função de regularização na equação de Alarcón *et al.* (2002), conforme apresentado na equação (4.14).

$$q_{oj}(q_{igj}) = 0,5 \left[1 + \tanh \left(\frac{q_{igj} - q_{igi}^*}{10^{-6}} \right) \right] \left[c_1 + c_2 \cdot q_{igj} + c_3 \cdot q_{igj}^2 + c_4 \cdot \ln(q_{igj} + 1) \right] \quad (4.14)$$

Para um melhor ajuste, recomenda-se a definição de um valor para q_{igi}^* ligeiramente inferior a vazão de ativação do poço. O ajuste da equação (4.14) a um conjunto de pontos que compõe a curva de eficiência de *gas lift* de um poço produtor pode ser visto na Figura 4.3.

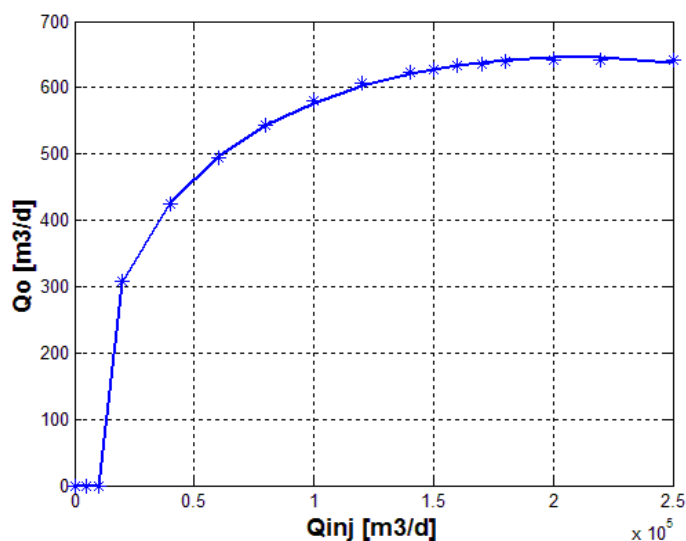


Figura 4.3 – Resultado do ajuste de uma curva com a adição de uma função de regularização para modelar um poço do tipo B.

No modelo proposto neste trabalho, considerou-se que a interação entre os poços é desprezível, o que é uma hipótese razoável em plataformas onde todos os poços produtores são satélites. Porém, em plataformas que possuem poços produzindo para um *manifold* submarino ou campos de terra onde os *manifolds* estão localizados a grandes distâncias da planta de processo, esta hipótese pode gerar erros significativos, sendo necessário incluir no modelo uma equação que a perda de carga na linha que liga o *manifold* à planta de processo e a vazão de óleo produzida.

As próximas seções irão apresentar os modelos resultantes da combinação das equações acima descritas.

4.1.5 Modelo de programação não-linear (NLP)

O modelo não-linear do problema de otimização da produção de poços que operam com o auxílio do *gas lift* contínuo com função objetivo operacional pode ser representado da seguinte forma:

$$\max_{q_{ig1}, \dots, q_{igN}} \sum_{i=1}^N q_{oi} \quad (4.15)$$

Sujeito a:

$$q_{o_i}(q_{ig_i}) = c_{1_i} + c_{2_i} q_{ig_i} + c_{3_i} q_{ig_i}^2 + c_{4_i} \ln(q_{ig_i} + 1) \quad (4.16)$$

$$q_{ig_i}^{\min} \leq q_{ig_i} \leq q_{ig_i}^{\max} \quad (4.17)$$

Para $i \in N_s$

$$q_{o_j}(q_{ig_j}) = 0.5 \left[1 + \tanh \left(\frac{q_{ig_j} - q_{ig_j}^*}{10^{-6}} \right) \right] \left[c_{1_j} + c_{2_j} q_{ig_j} + c_{3_j} q_{ig_j}^2 + c_{4_j} \ln(q_{ig_j} + 1) \right] \quad (4.18)$$

$$q_{ig_j}^{\min} \leq q_{ig_j} \leq q_{ig_j}^{\max} \quad (4.19)$$

Para $j \in N_{ns}$

$$\sum_{i=1}^N \frac{100}{(100 - BSW_i)} q_{o_i} \leq q_{lrc} \quad (4.20)$$

$$\sum_{i=1}^N \frac{BSW_i}{(100 - BSW_i)} q_{o_i} \leq q_{wrc} \quad (4.21)$$

$$\sum_{i=1}^N \left[RGO_i q_{o_i} + q_{ig_i} \right] \leq q_{gtc} \quad (4.22)$$

em que N_s é o conjunto dos poços surgentes e N_{ns} o conjunto dos poços não surgentes, ou seja, que possuem certa vazão de ativação.

Com a função objetivo econômica tem-se:

$$\max_{q_{ig_1}, \dots, q_{ig_N}} \sum_{i=1}^N \left[\left(D_o + D_{pg} RGO_i - D_w \frac{BSW}{(100 - BSW)} - D_{ig} RGO_i - D_{oc} \right) q_{o_i} - D_{ig} q_{ig_i} \right] \quad (4.23)$$

Sujeito a:

$$q_{o_i}(q_{ig_i}) = c_{1_i} + c_{2_i} q_{ig_i} + c_{3_i} q_{ig_i}^2 + c_{4_i} \ln(q_{ig_i} + 1) \quad (4.24)$$

$$q_{ig_i}^{\min} \leq q_{ig_i} \leq q_{ig_i}^{\max} \quad (4.25)$$

Para $i \in N_s$

$$q_{o_j}(q_{ig_j}) = 0.5 \left[1 + \tanh \left(\frac{q_{ig_j} - q_{ig_j}^*}{10^{-6}} \right) \right] \left[c_{1_j} + c_{2_j} q_{ig_j} + c_{3_j} q_{ig_j}^2 + c_{4_j} \ln(q_{ig_j} + 1) \right] \quad (4.26)$$

$$q_{ig_j}^{\min} \leq q_{ig_j} \leq q_{ig_j}^{\max} \quad (4.27)$$

Para $j \in N_{ns}$

$$\sum_{i=1}^N \frac{100}{(100 - BSW_i)} q_{o_i} \leq q_{lrc} \quad (4.28)$$

$$\sum_{i=1}^N \frac{BSW_i}{(100 - BSW_i)} q_{o_i} \leq q_{wrc} \quad (4.29)$$

$$\sum_{i=1}^N \left[RGO_i q_{o_i} + q_{ig_i} \right] \leq q_{gtc} \quad (4.30)$$

4.1.6 Modelos de programação linear inteira mista (MILP)

Método Clássico:

Abaixo segue o modelo do problema de otimização da produção de poços que operam com *gas lift* contínuo seguindo o método clássico de linearização por partes descrito na Seção 3.2.2 deste trabalho.

$$\max_{y, \lambda} \sum_{i=1}^N \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \quad (4.31)$$

$$\sum_{k=1}^{p-1} y_{i,k} = 1 \quad \forall i = 1, \dots, N \quad (4.32)$$

$$y_{i,k} \in \{0,1\} \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p-1 \quad (4.33)$$

$$\lambda_{i,k} \geq 0 \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p \quad (4.34)$$

$$\sum_{k=1}^p \lambda_{i,k} = 1 \quad \forall i = 1, \dots, N \quad (4.35)$$

$$\lambda_{i,1} \leq y_{i,1} \quad \forall i = 1, \dots, N \quad (4.36)$$

$$\lambda_{i,k} \leq y_{i,k-1} + y_{i,k} \quad \forall i = 1, \dots, N \quad \forall k = 2, \dots, p-1 \quad (4.37)$$

$$\lambda_{i,p} \leq y_{i,p-1} \quad \forall i = 1, \dots, N \quad (4.38)$$

$$\sum_{i=1}^N \left[\left(\frac{100}{100 - BSW_i} \right) \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \right] \leq q_{ltc} \quad (4.39)$$

$$\sum_{i=1}^N \left[\left(\frac{BSW_i}{100 - BSW_i} \right) \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \right] \leq q_{wtc} \quad (4.40)$$

$$\sum_{i=1}^N \left(RGO_i \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} + \sum_{k=1}^p \lambda_{i,k} q_{ig_{i,k}} \right) \leq q_{gtc} \quad (4.41)$$

$$q_{ig_j}^{\min} \leq \sum_{k=1}^p \lambda_{i,k} q_{ig_{i,k}} \leq q_{ig_j}^{\max} \quad \forall i = 1, \dots, N \quad (4.42)$$

Método das Estruturas Especiais:

Abaixo segue o modelo do problema de otimização da produção de poços que operam com *gas lift* contínuo seguindo o método das estruturas especiais de linearização por partes descrito na Seção 3.2.2 deste trabalho.

$$\max_{\lambda} \sum_{i=1}^N \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \quad (4.43)$$

$$\lambda_{i,k} \geq 0 \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p \quad (4.44)$$

$$\lambda_{i,k} \in SOS2 \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p \quad (4.45)$$

$$\sum_{k=1}^p \lambda_{i,k} = 1 \quad \forall i = 1, \dots, N \quad (4.46)$$

$$\sum_{i=1}^N \left[\left(\frac{100}{100 - BSW_i} \right) \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \right] \leq q_{lrc} \quad (4.47)$$

$$\sum_{i=1}^N \left[\left(\frac{BSW_i}{100 - BSW_i} \right) \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \right] \leq q_{wrc} \quad (4.48)$$

$$\sum_{i=1}^N \left(RGO_i \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} + \sum_{k=1}^p \lambda_{i,k} q_{ig_{i,k}} \right) \leq q_{gtc} \quad (4.49)$$

$$q_{igj}^{\min} \leq \sum_{k=1}^p \lambda_{i,k} q_{ig_{i,k}} \leq q_{igj}^{\max} \quad \forall i = 1, \dots, N \quad (4.50)$$

Método da Segmentação Linear

Abaixo segue o modelo do problema de otimização da produção de poços que operam com *gas lift* contínuo seguindo o método da segmentação linear de linearização por partes descrito na Seção 3.2.2 deste trabalho.

$$\max_{y, Q_{ig}} \sum_{i=1}^N \sum_{k=1}^p \left(\alpha_{i,k} y_{i,k} + \beta_{i,k} Q_{ig_{i,k}} \right) \quad (4.51)$$

$$\alpha_{i,k} = q_{o_{i,k}} - \beta_{i,k} q_{ig_{i,k}} \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p-1 \quad (4.52)$$

$$\beta_{i,k} = \frac{q_{o_{i,k+1}} - q_{o_{i,k}}}{q_{ig_{i,k+1}} - q_{ig_{i,k}}} \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p-1 \quad (4.53)$$

$$\sum_{k=1}^{p-1} y_{i,k} = 1 \quad \forall i = 1, \dots, N \quad (4.54)$$

$$y_{i,k} \in \{0,1\} \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p-1 \quad (4.55)$$

$$q_{ig_{i,k}} y_{i,k} \leq Q_{ig_{i,k}} \leq q_{ig_{i,k+1}} y_{i,k} \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p-1 \quad (4.56)$$

$$\sum_{i=1}^N \left[\left(\frac{100}{100 - BSW_i} \right) \sum_{k=1}^p (\alpha_{i,k} y_{i,k} + \beta_{i,k} Q_{ig_{i,k}}) \right] \leq q_{lrc} \quad (4.57)$$

$$\sum_{i=1}^N \left[\left(\frac{BSW_i}{100 - BSW_i} \right) \sum_{k=1}^p (\alpha_{i,k} y_{i,k} + \beta_{i,k} Q_{ig_{i,k}}) \right] \leq q_{wrc} \quad (4.58)$$

$$\sum_{i=1}^N \left[RGO_i \sum_{k=1}^p (\alpha_{i,k} y_{i,k} + \beta_{i,k} Q_{ig_{i,k}}) + \sum_{k=1}^p Q_{ig_{i,k}} \right] \leq q_{grc} \quad (4.59)$$

$$q_{igj}^{\min} \leq \sum_{k=1}^p Q_{ig_{i,k}} \leq q_{igj}^{\max} \quad \forall i = 1, \dots, N \quad (4.60)$$

4.2 Otimização da produção em cenário de queda de compressores

Conforme foi explicado na Seção 2.1.2 deste trabalho, as plataformas geralmente são dimensionadas para operar com dois compressores, sendo que o terceiro fica em *stand-by*.

Quando mais de um compressor apresenta uma falha, a capacidade de compressão fica severamente comprometida e parte do gás passa a ser queimado no *flare*. Neste momento, o engenheiro precisa tomar uma decisão que pode se restringir à produção dos poços para se ajustar à nova capacidade de compressão ou manter a queima elevada até o restabelecimento da operação de um dos compressores.

Esta decisão também é afetada pelo fato de que a queima não pode ser superior aos limites estabelecidos pelos órgãos governamentais.

Na Figura 4.4, pode-se ver um cenário real onde ocorreu a falha de dois compressores, sendo que o processo passou a operar com restrições severas na capacidade de compressão até o restabelecimento de um dos compressores, que ocorreu cinco dias após a falha. Durante este período, a perda de produção foi controlada pela queima, ou seja, a plataforma passou a queimar mais gás do que o normal por certo período de tempo, respeitando os limites estabelecidos pelos órgãos governamentais.




Figura 4.4 – Cenário de queda de compressores com aumento da queima para o *flare*.

De modo geral, pode-se dizer que o objetivo da otimização em um cenário como este é maximizar a produção de óleo minimizando a queima e respeitando as restrições impostas pelos poços, planta de processamento e o limite de queima estabelecido pelos órgãos governamentais.

Este cenário caracteriza um problema de otimização multiobjetivo, que pode ser genericamente formulado da seguinte forma:

$$\max \{F(x) = [f_1(x), f_2(x), \dots, f_R(x)]^T\}$$

Sujeito a:

$$h_i(x) = 0 \quad i = 1, 2, \dots, m$$

$$g_j(x) \leq 0 \quad j = 1, 2, \dots, p$$

em que $\mathbf{x} = [x_1, x_2, \dots, x_n]$ e $\mathbf{F}(\mathbf{x})$ é um vetor de funções objetivo.

Existem diversos métodos para representar um problema de otimização multiobjetivo, porém, neste trabalho, optou-se pelo método da soma ponderada, no qual os objetivos são combinados em uma única função e ponderados por um peso (w) que pode variar de 0 a 1 e cuja soma deve ser 1.

O modelo de programação linear inteira mista (MILP) proposto para representar o problema acima descrito é formulado a seguir. Conforme pode ser visto na equação (4.61), devido à diferença de ordem de grandeza dos números que representam a produção de óleo e a vazão de queima de gás, normalizou-se o problema dividindo o somatório das vazões de óleo pela máxima produção de óleo possível (q_o^{max}) e a vazão de queima de gás pelo limite máximo de queima ($queima^{max}$).

A queima também é limitada por um limite máximo permitido através da equação (4.70).

$$\max_{\lambda, q_{queima}, y} \left[w \frac{\sum_{i=1}^N \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}}}{q_o^{max}} - (1-w) \frac{q_{queima}}{queima^{max}} \right] \quad (4.61)$$

$$\lambda_{i,k} \geq 0 \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p \quad (4.62)$$

$$\lambda_{i,k} \in SOS2 \quad \forall i = 1, \dots, N \quad \forall k = 1, \dots, p \quad (4.63)$$

$$\sum_{k=1}^p \lambda_{i,k} = y_i \quad \forall i = 1, \dots, N \quad (4.64)$$

$$y_i \in \{0,1\} \quad \forall i = 1, \dots, N \quad (4.65)$$

$$\sum_{i=1}^N \left[\left(\frac{100}{100 - BSW_i} \right) \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \right] \leq q_{lic} \quad (4.66)$$

$$\sum_{i=1}^N \left[\left(\frac{BSW_i}{100 - BSW_i} \right) \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} \right] \leq q_{wtc} \quad (4.67)$$

$$\sum_{i=1}^N \left(RGO_i \sum_{k=1}^p \lambda_{i,k} q_{o_{i,k}} + \sum_{k=1}^p \lambda_{i,k} q_{ig_{i,k}} - q_{queima} \right) \leq q_{gtc} \quad (4.68)$$

$$q_{igj}^{\min} y_i \leq \sum_{k=1}^p \lambda_{i,k} q_{ig_{i,k}} \leq q_{igj}^{\max} y_i \quad \forall i = 1, \dots, N \quad (4.69)$$

$$q_{queima} \leq queima^{\max} \quad (4.70)$$

Neste modelo, adicionou-se uma variável de decisão binária (y) para determinar a abertura ou fechamento do poço.

4.3 Otimização da produção considerando a pressão à montante da válvula *choke* dos poços

Quando uma plataforma possui um número significativo de poços surgentes, no caso de uma restrição severa na capacidade de compressão, a decisão de cortar o *gas lift* de alguns poços com o objetivo de maximizar a produção de óleo pode não ser suficiente.

Caso o modelo possua uma variável binária para definir a abertura ou fechamento dos poços (como no modelo de otimização multiobjetivo descrito na Seção 4.2), uma solução seria fechar os poços surgentes com elevada razão gás-óleo (RGO), porém, esta ação poderá resultar em uma produção de óleo inferior àquela que seria obtida pelo operador da plataforma que tem uma variável de decisão a mais que é a abertura do *choke* de produção.

Para tratar cenários como este, propôs-se um modelo de otimização considerando como variável de decisão, além da vazão de *gas lift* e a abertura e fechamento dos poços, a pressão à montante da válvula *choke* de produção.

Este modelo é adequado para plataformas com poços satélites, onde a pressão à jusante do *choke* pode ser considerada aproximadamente constante e com valor conhecido. Com a queda de pressão através da válvula, o operador ou o sistema de controle automático pode determinar a abertura da mesma que irá resultar neste valor.

Com o acréscimo da pressão à montante da válvula *choke* de produção (também conhecida como pressão na cabeça do poço), a curva de eficiência de *gas lift* passa a ser uma superfície, como está exemplificada na Figura 4.5.




Figura 4.5 – Superfície representando a produção de óleo de um poço como função da pressão na cabeça do poço e da vazão de *gas lift*.

Abaixo, segue o modelo de programação linear inteira mista (MILP) proposto para representar o problema acima descrito.

$$\max_{\lambda, q_{queima}, y} \left[w \frac{\sum_{i=1}^N \sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} q_{o_{i,j,k}}}{q_o^{\max}} - (1-w) \frac{q_{queima}}{queima^{\max}} \right] \quad (4.71)$$

$$\lambda_{i,j,k} \geq 0 \quad \forall i = 1, \dots, N \quad \forall j = 1, \dots, p \quad \forall k = 1, \dots, q \quad (4.72)$$

$$\lambda_{i,j,k} \in SOS2 \quad \forall i = 1, \dots, N \quad \forall j = 1, \dots, p \quad \forall k = 1, \dots, q \quad (4.73)$$

$$\sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} = y_i \quad \forall i = 1, \dots, N \quad (4.74)$$

$$y_i \in \{0,1\} \quad \forall i = 1, \dots, N \quad (4.75)$$

$$\sum_{i=1}^N \left[\left(\frac{100}{100 - BSW_i} \right) \sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} q_{o_{i,j,k}} \right] \leq q_{ltc} \quad (4.76)$$

$$\sum_{i=1}^N \left[\left(\frac{BSW_i}{100 - BSW_i} \right) \sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} q_{o_{i,j,k}} \right] \leq q_{wrc} \quad (4.77)$$

$$\sum_{i=1}^N \left(RGO_i \sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} q_{o_{i,j,k}} + \sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} q_{ig_{i,j,k}} - q_{queima} \right) \leq q_{gtc} \quad (4.78)$$

$$q_{igj}^{\min} y_i \leq \sum_{j=1}^p \sum_{k=1}^q \lambda_{i,j,k} q_{ig_{i,j,k}} \leq q_{igj}^{\max} y_i \quad \forall i = 1, \dots, N \quad (4.79)$$

$$q_{queima} \leq queima^{\max} \quad (4.80)$$

Capítulo 5

Resultados e Discussões

5.1 Cenário de estudo

Para este estudo foi considerado um conjunto de doze poços satélites produzindo para uma plataforma marítima de produção. Os poços estão conectados ao mesmo *header* de *gas lift*, o que faz necessária uma estratégia de alocação ótima do gás, e produzem para dois trens de separação que possuem aproximadamente a mesma capacidade e pressão no separador de primeiro estágio, o que possibilitou uma simplificação no modelo considerando-se que existe um único trem de separação com capacidades equivalentes ao dobro das capacidades individuais.

Na Figura 5.1, são apresentadas as curvas de eficiência de *gas lift* dos doze poços que compõe o cenário de estudo, onde se observa a existência de poços dos tipos A e B descritos na Seção 4.1.4 deste trabalho.




Figura 5.1 – Curvas de eficiência de *gas lift* dos 12 poços produtores.

As curvas de eficiência foram geradas através do uso de modelos dos poços implementados em um simulador de escoamento multifásico, proprietário da Petrobras, chamado MARLIM II.

Este simulador utiliza correlações de escoamento multifásico para o cálculo do gradiente de pressão nos poços e linhas, bem como correlações adicionais para o cálculo das propriedades dos fluidos em função da pressão e temperatura.

Os modelos dos poços foram ajustados com base nos dados obtidos nos testes de produção realizados em cada poço produtor.

Na Tabela 5.1 estão listados o RGO e BSW dos poços produtores.

Tabela 5.1 – Parâmetros dos poços produtores.

Poço	RGO [m ³ /m ³]	BSW [%]	Poço	RGO [m ³ /m ³]	BSW [%]
1	76	30	7	58	5
2	130	17	8	82	32
3	75	7	9	76	44
4	103	68	10	60	60
5	78	52	11	60	65
6	78	36	12	114	35

Na Tabela 5.2 estão os valores de referência utilizados na formulação da função objetivo econômica para os preços do óleo e do gás no mercado internacional, bem como valores médios a nível mundial para os custos de tratamento da água produzida, do óleo e do gás (compressão + secagem do gás).

Tabela 5.2 – Preços e custos de referência adotados (WorldOil, 2011).

	Valor	Unidade
D _o	90	US\$/bbl
D _{pg}	3,75	US\$/10 ³ ft ³
D _w	12	US\$/bbl
D _{ig}	1,5	US\$/10 ³ ft ³
D _{oc}	4	US\$/bbl

Na maioria dos casos estudados neste trabalho, adotaram-se as restrições operacionais listadas na Tabela 5.3.

Tabela 5.3 – Restrições operacionais da plataforma.

Disponibilidade de gás para <i>gas lift</i>	1.000.000	Nm ³ /d
Capacidade de compressão	2.000.000	Nm ³ /d
Capacidade de tratamento de líquido	12.000	m ³ /d
Capacidade de tratamento de água	6.000	m ³ /d

Todos os estudos de caso deste trabalho foram realizados em um computador Dell Pentium Dual-Core de 2,20 GHz com 3,46 GB de RAM e utilizando o sistema operacional Windows XP. Além disto, todos os problemas de otimização foram implementados no *software* GAMS e resolvidos com a aplicação dos *solvers* SNOPT (para a estratégia NLP) e CPLEX (para as estratégias MILP).

5.2 Comparação entre a função objetivo econômica e a operacional

Com o intuito de comparar os resultados obtidos através do uso das duas funções objetivo, resolveu-se para o cenário de estudo descrito na Seção 5.1 os modelos representados pelas equações (4.15) a (4.22) (modelo com função objetivo operacional) e (4.23) a (4.30) (modelo com função objetivo econômica).

Para viabilizar a comparação, converteram-se os resultados obtidos com a função objetivo operacional para valores monetários e calculou-se a diferença no lucro para diferentes custos de tratamento de óleo, água e gás da unidade, bem como para diferentes preços do óleo e gás produzido no mercado internacional. Em todos os casos simulados, as condições operacionais da unidade e dos poços foram mantidas constantes, ou seja, as capacidades da plataforma e os parâmetros característicos dos poços não foram alterados.

Os resultados obtidos, considerando o preço do barril de petróleo no mercado internacional de US\$ 70,00, podem ser vistos nas Tabelas 5.4 a 5.6. Nas Tabelas 5.7 a 5.9 estão os resultados obtidos considerando-se o preço do barril de petróleo no mercado internacional de US\$ 90,00. Já nas Tabelas 5.10 a 5.12 estão os resultados obtidos considerando-se o preço do barril de petróleo no mercado internacional de US\$ 120,00.

Tabela 5.4 – Resultados obtidos para diferentes valores do custo de tratamento de água e $D_o = 70$ US\$/bbl.

D_w [US\$/bbl]	$Z_{\text{econômico}}$ [US\$/d]	$Z_{\text{operacional}}$ [US\$/d]	Diferença [US\$/d]
1,5	3.314.400	3.306.741	7.658
2	3.301.900	3.294.247	7.653
4	3.251.700	3.244.268	7.432
6	3.201.600	3.194.289	7.311
12	3.051.200	3.044.353	6.847

Tabela 5.5 – Resultados obtidos para diferentes valores de custo de tratamento de gás e
Do = 70 US\$/bbl.

D _{ig} [US\$/10 ³ ft ³]	Z _{econômico} [US\$/d]	Z _{operacional} [US\$/d]	Diferença [US\$/d]
0,5	3.099.200	3.098.384	816
1,0	3.074.500	3.071.368	3.132
1,5	3.051.200	3.044.353	6.847
2,0	3.029.000	3.017.337	11.662

Tabela 5.6 – Resultados obtidos para diferentes valores do custo de tratamento do óleo e
Do = 70 US\$/bbl.

D _{oc} [US\$/bbl]	Z _{econômico} [US\$/d]	Z _{operacional} [US\$/d]	Diferença [US\$/d]
1,5	3.177.200	3.170.574	6.626
2	3.152.000	3.145.329	6.670
4	3.051.200	3.044.353	6.847
6	2.950.400	2.943.376	7.024

Tabela 5.7 – Resultados obtidos para diferentes valores do custo de tratamento de água
e Do = 90 US\$/bbl.

D _w [US\$/bbl]	Z _{econômico} [US\$/d]	Z _{operacional} [US\$/d]	Diferença [US\$/d]
1,5	4.322.100	4.315.878	6.222
2	4.309.600	4.303.383	6.217
4	4.259.500	4.253.404	6.096
6	4.209.400	4.203.426	5.974
12	4.059.100	4.053.489	5.611

Tabela 5.8– Resultados obtidos para diferentes valores de custo de tratamento de gás e
Do = 90 US\$/bbl.

D _{ig} [US\$/10 ³ ft ³]	Z _{econômico} [US\$/d]	Z _{operacional} [US\$/d]	Diferença [US\$/d]
0,5	4.108.200	4.107.498	702
1,0	4.083.100	4.080.493	2.607
1,5	4.059.100	4.053.489	5.611
2,0	4.036.200	4.026.485	9.715

Tabela 5.9 – Resultados obtidos para diferentes valores do custo de tratamento do óleo e
Do = 90 US\$/bbl.

D _{oc} [US\$/bbl]	Z _{econômico} [US\$/d]	Z _{operacional} [US\$/d]	Diferença [US\$/d]
1,5	4.185.200	4.179.710	5.490
2	4.160.000	4.154.466	5.534
4	4.059.100	4.053.489	5.611
6	3.958.200	3.952.513	5.687

Tabela 5.10 – Resultados obtidos para diferentes valores do custo de tratamento de água e $D_o = 120$ US\$/bbl.

D_w [US\$/bbl]	$Z_{\text{econômico}}$ [US\$/d]	$Z_{\text{operacional}}$ [US\$/d]	Diferença [US\$/d]
1,5	5.835.900	5.831.156	4.744
2	5.823.400	5.818.661	4.739
4	5.773.300	5.768.682	4.618
6	5.723.300	5.718.703	4.596
12	5.573.200	5.568.767	4.433

Tabela 5.11 – Resultados obtidos para diferentes valores de custo de tratamento de gás e $D_o = 120$ US\$/bbl.

D_{ig} [US\$/10 ³ ft ³]	$Z_{\text{econômico}}$ [US\$/d]	$Z_{\text{operacional}}$ [US\$/d]	Diferença [US\$/d]
0,5	5.623.300	5.622.798	502
1,0	5.597.800	5.595.782	2.018
1,5	5.573.200	5.568.767	4.433
2,0	5.549.400	5.541.752	7.648

Tabela 5.12 – Resultados obtidos para diferentes valores do custo de tratamento do óleo e $D_o = 120$ US\$/bbl.

D_{oc} [US\$/bbl]	$Z_{\text{econômico}}$ [US\$/d]	$Z_{\text{operacional}}$ [US\$/d]	Diferença [US\$/d]
1,5	5.699.300	5.694.988	4.312
2	5.674.100	5.669.744	4.356
4	5.573.200	5.568.767	4.433
6	5.472.300	5.467.790	4.509

Uma análise dos resultados das tabelas mostra que para todos os casos estudados, o uso de uma função objetivo operacional resulta em perdas significativas no lucro obtido com a operação.

Nas Figuras 5.2 a 5.4, pode-se ver um conjunto de gráficos da variação da diferença no lucro obtido com as duas funções objetivos em função do custo do barril de petróleo no mercado internacional e dos custos de tratamento dos fluidos produzidos. Nestes gráficos, pode-se observar que a diferença no lucro obtido com as duas funções objetivo estudadas varia de diferentes formas a depender do custo de tratamento que está sendo analisado.

No gráfico da Figura 5.2, as curvas são paralelas e se assemelham a polinômios do segundo grau, enquanto que no gráfico da Figura 5.3, as curvas partem praticamente do mesmo ponto e divergem com o aumento do custo de tratamento do gás, sendo mais bem aproximadas por funções de potência. Por fim, no gráfico da Figura 5.3, as curvas se assemelham a retas paralelas.

O aumento da diferença entre os resultados da função objetivo econômica e operacional em função do aumento dos custos de tratamento de óleo (Figura 5.4) e gás (Figura 5.3) pode ser explicado pelo fato da função objetivo operacional não ser sensível a variações nestes parâmetros, ou seja, as vazões totais de produção de óleo e gás não variam com o aumento dos custos de tratamento destes fluidos, diferentemente do que ocorre com a função objetivo econômica que considera o efeitos destes parâmetros e permite o ajuste das vazões totais de óleo e gás em resposta ao aumentos dos custos de tratamento.

Com base nas Figuras 5.2 a 5.4, conclui-se também que o preço do petróleo no mercado internacional tem um impacto significativo no valor da diferença no lucro obtido com as duas funções objetivos, sendo que, quanto menor for o seu valor, maior será a diferença observada.

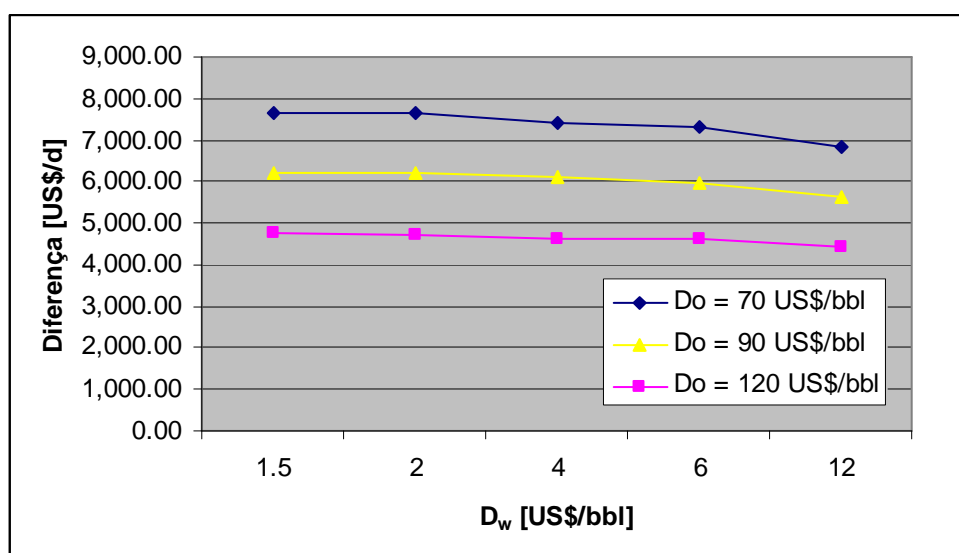


Figura 5.2 – Gráfico da diferença entre os resultados da função objetivo econômica e operacional para diferentes valores de D_w e D_o .




Figura 5.3 – Gráfico da diferença entre os resultados da função objetivo econômica e operacional para diferentes valores de D_{ig} e D_o .

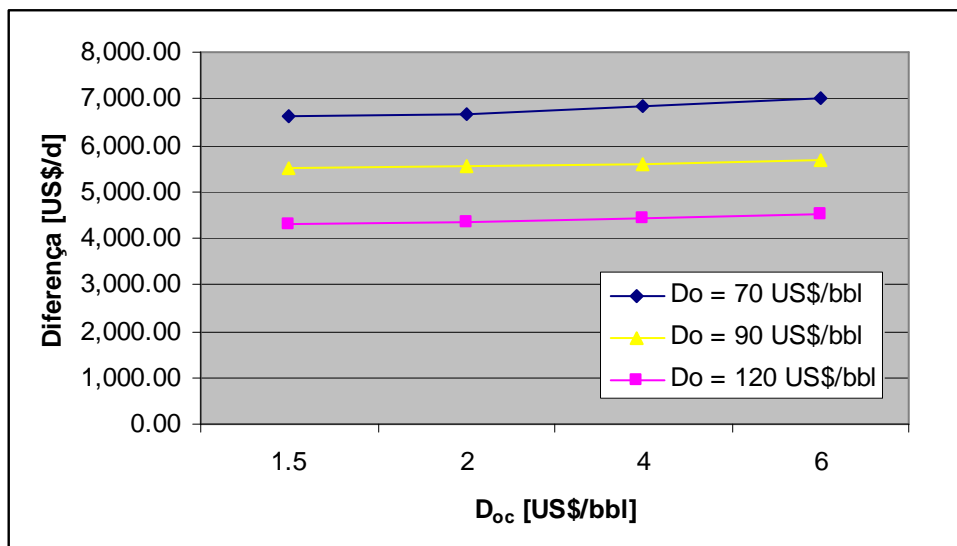


Figura 5.4 – Gráfico da diferença entre os resultados da função objetivo econômica e operacional para diferentes valores de D_{oc} e D_o .

5.3 Comparação entre os resultados obtidos com o NLP e o MILP

Para realizar a comparação entre as estratégias de otimização propostas, utilizou-se apenas o modelo com a função objetivo operacional, sendo que, em todos os testes realizados, as capacidades da plataforma e os parâmetros característicos dos poços foram mantidos constantes.

A decisão de se utilizar apenas a função objetivo operacional nos testes teve como intuito simplificar o procedimento, não havendo qualquer restrição quanto à aplicação das estratégias estudadas no modelo com a função objetivo econômica.

A estratégia de otimização que utiliza o algoritmo SQP exige a definição de uma estimativa inicial de vazão de *gas lift* para cada poço produtor, que neste estudo de caso, foi assumida como zero para todos os poços. Esta condição, apesar de certamente não ser a ótima, está dentro da região viável do problema.

Para os algoritmos baseados na estratégia de linearização por partes, usaram-se 26 pontos por poço para representar a curva de eficiência de *gas lift* por poço. Na Seção 5.5 é feita uma análise do número de pontos para justificar esta escolha.

Na Tabela 5.13, pode-se ver um lista com as estratégias de otimização avaliadas neste trabalho e os modelos com os quais elas se relacionam.

Tabela 5.13 – Relação entre as estratégias de otimização testadas e os modelos implementados.

Estratégia	Modelo
NLP	Equações (4.15) a (4.22)
MILP-CM	Equações (4.31) a (4.42)
MILP-LSM	Equações (4.51) a (4.60)
MILP-SSM	Equações (4.43) a (4.50)

Como o tempo de CPU é um parâmetro fortemente influenciado pelo computador utilizado e pelos processos em execução na máquina no momento da realização do teste, visando garantir a robustez do método de avaliação, optou-se por registrar este indicador de eficiência como uma média do tempo CPU de sessenta execuções do algoritmo em avaliação.

Os resultados obtidos podem ser vistos na Tabela 5.14.

Tabela 5.14 – Resultados obtidos com os diferentes algoritmos de otimização testados.

Algoritmo	Gas Lift Total [Nm ³ /d]	Óleo [m ³ /d]	Iterações	Tempo de CPU [s]	
				Média	Mediana
MILP-CM	1.000.000	7.638	3	0,117	0,125
MILP-LSM	1.000.000	7.638	337	0,186	0,187
MILP-SSM	1.000.000	7.638	63	0,085	0,093
NLP	826.860	8.027	81	0,072	0,078

Uma análise dos resultados da Tabela 5.14 indica que a vazão de óleo obtida com o NLP foi superior ao obtido com as estratégias de linearização por partes e com um consumo de gás significativamente inferior. Esta diferença pode ser explicada pelo fato das duas abordagens utilizarem formas distintas de representar as curvas de eficiência de *gas lift*, sendo que a qualidade dos resultados obtidos com o uso da linearização por partes está fortemente vinculada ao número e disposição dos pontos disponíveis para representar a curva, conforme foi explicado na Seção 3.2.2 deste trabalho.

Comparando-se as estratégias com base no número de iterações, a formulação MILP em conjunto com o algoritmo clássico de linearização por partes apresentou o melhor resultado. Porém, esta superioridade não se confirmou com a análise do tempo de CPU.

Na análise pelo tempo de CPU, o NLP se mostrou o mais eficiente, porém, é importante ressaltar que o tempo de CPU de todos os métodos testados foi muito baixo, sendo a diferença quase imperceptível para o usuário final. Logo, para o problema em questão, o critério do tempo de CPU indica que qualquer um dos métodos testados poderia ser utilizado em uma aplicação prática.

Pelo fato da estratégia NLP ter apresentado uma maior produção total de óleo para um menor consumo de gás, além de ter exibido valores satisfatórios para o número de iterações e o menor tempo de CPU, conclui-se que, para este caso de estudo, esta estratégia apresentou o melhor resultado geral.

Na próxima seção deste trabalho, será apresentado um estudo do impacto da estimativa inicial no resultado do algoritmo SQP.

5.4 Análise de sensibilidade à condição inicial do algoritmo SQP

Durante o processo de avaliação dos resultados obtidos com a estratégia baseada no uso do algoritmo SQP, observou-se que o mesmo era sensível ao valor adotado para a estimativa inicial.

Do ponto de vista teórico, esta sensibilidade pode ser explicada pelo fato da função objetivo não ser côncava, o que indica que o problema possui mais de um ótimo local.

A concavidade pode ser avaliada pela equação abaixo:

$$f[cx'+(1-c)x''] \geq cf(x') + (1-c)f(x'') \quad 0 \leq c \leq 1$$

em que x' e x'' são dois pontos quaisquer pertencentes à região viável do problema.

Esta equação indica que uma função é côncava, quando dada uma linha reta traçada entre quaisquer dois pontos pertencentes ao domínio da função (x' e x''), o valor da função para todos os pontos localizados no intervalo entre x' e x'' é sempre superior ao valor da reta que une os valores da função avaliada em x' e x'' .

O gráfico da Figura 5.5 esboça a curva de eficiência do *gas lift* com o uso da função de regularização.

Neste gráfico, traçou-se uma linha reta ligando os seus dois pontos extremos com o objetivo de analisar a concavidade da curva de eficiência. Como existem trechos do gráfico que estão abaixo da linha reta, pode-se afirmar que esta função não é côncava.

Com esta análise, conclui-se que a função objetivo não é côncava e, conseqüentemente, o problema pode apresentar mais de um ótimo local, o que explica a sensibilidade do problema de otimização em relação à estimativa inicial.




Figura 5.5 – Análise de concavidade da curva de eficiência.

Para avaliar o impacto da escolha da estimativa inicial no resultado obtido com a otimização, planejou-se um experimento que consistia na geração de um conjunto significativo de cenários de estimativas iniciais baseados em números aleatórios seguindo uma distribuição uniforme, cujos limites mínimos e máximos eram condizentes com os limites dos poços em estudo (0 a 300.000 Nm³/d para todos os poços).

Após gerar trezentas combinações de estimativas iniciais seguindo o procedimento acima descrito, filtraram-se os resultados com o objetivo de excluir estimativas que violavam a restrição de máxima vazão de *gas lift* disponível para a plataforma, o que resultou em um conjunto de duzentas e oitenta e seis combinações.

Os resultados obtidos foram analisados graficamente e algumas estatísticas foram geradas para auxiliar na sua interpretação.

O procedimento utilizado está representado de forma detalhada na Figura 5.6.

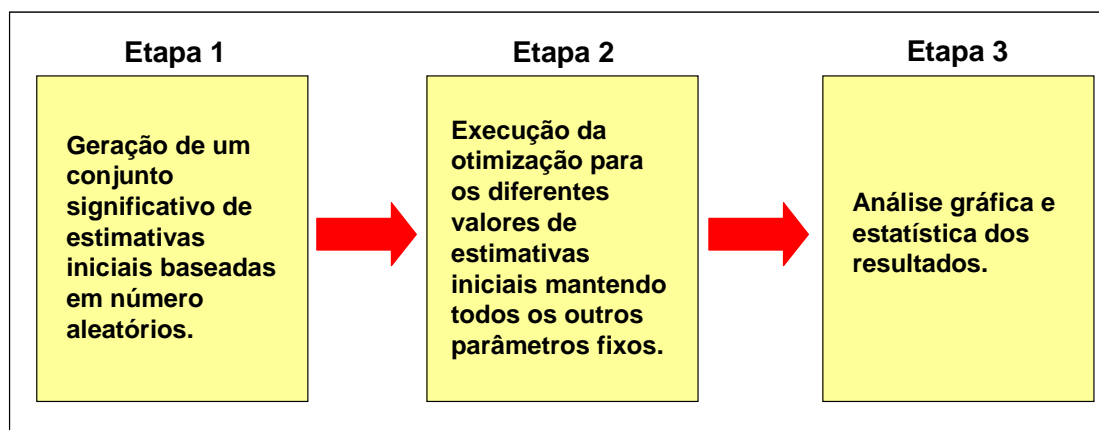


Figura 5.6 – Fluxograma da metodologia utilizada para analisar a sensibilidade do SQP à estimativa inicial.

Na Figura 5.7, pode-se ver um conjunto de gráficos com os valores das estimativas iniciais geradas para quatro poços através da aplicação da metodologia descrita acima. Uma análise destes gráficos mostra que os valores das estimativas iniciais estão distribuídos uniformemente no interior do intervalo estabelecido para cada poço.

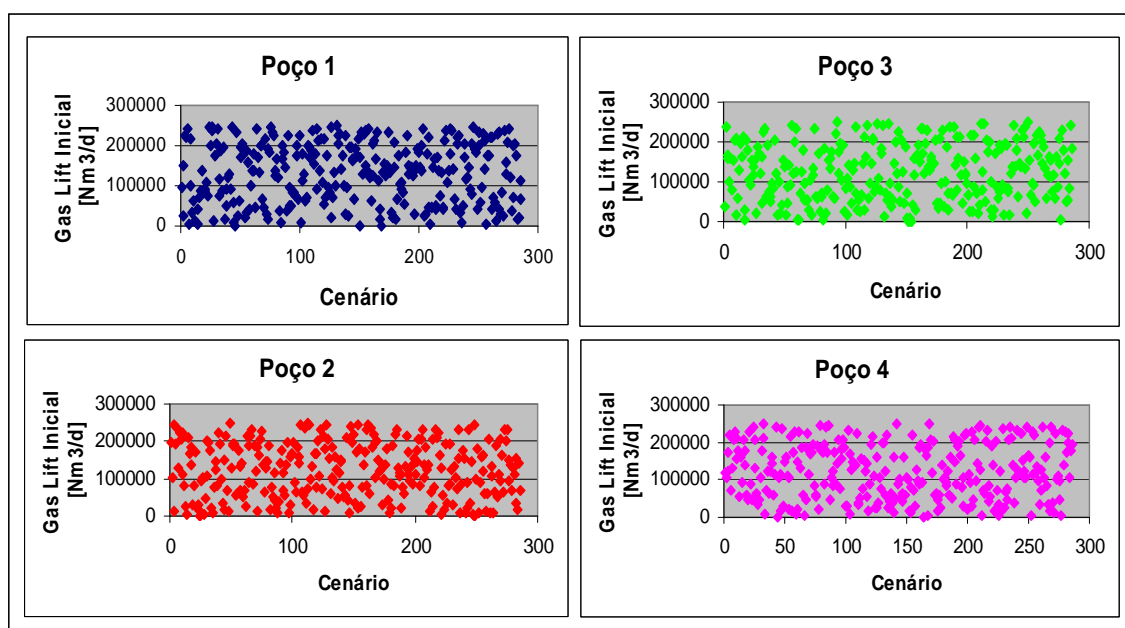


Figura 5.7 – Distribuição da estimativa inicial em função do cenário para quatro poços do caso de estudo.

Na Tabela 5.15, podem-se ver os valores considerados, neste estudo de caso, para as restrições da plataforma.

Tabela 5.15 – Restrições operacionais impostas.

Disponibilidade de gás para <i>gas lift</i>	3.000.000	Nm ³ /d
Capacidade de compressão	3.000.000	Nm ³ /d
Capacidade de tratamento de líquido	16.000	m ³ /d
Capacidade de tratamento de água	6.000	m ³ /d

Com o objetivo de simplificar o problema, optou-se por não restringir a disponibilidade de gás para *gas lift*, o que foi executado igualando o valor desta restrição ao da capacidade de compressão da plataforma.

Após executar a otimização para todos os duzentos e oitenta e seis cenários pré-definidos, esboçou-se um gráfico da vazão total de óleo produzida como função dos diferentes cenários de estudo. Este gráfico pode ser observado na Figura 5.8.

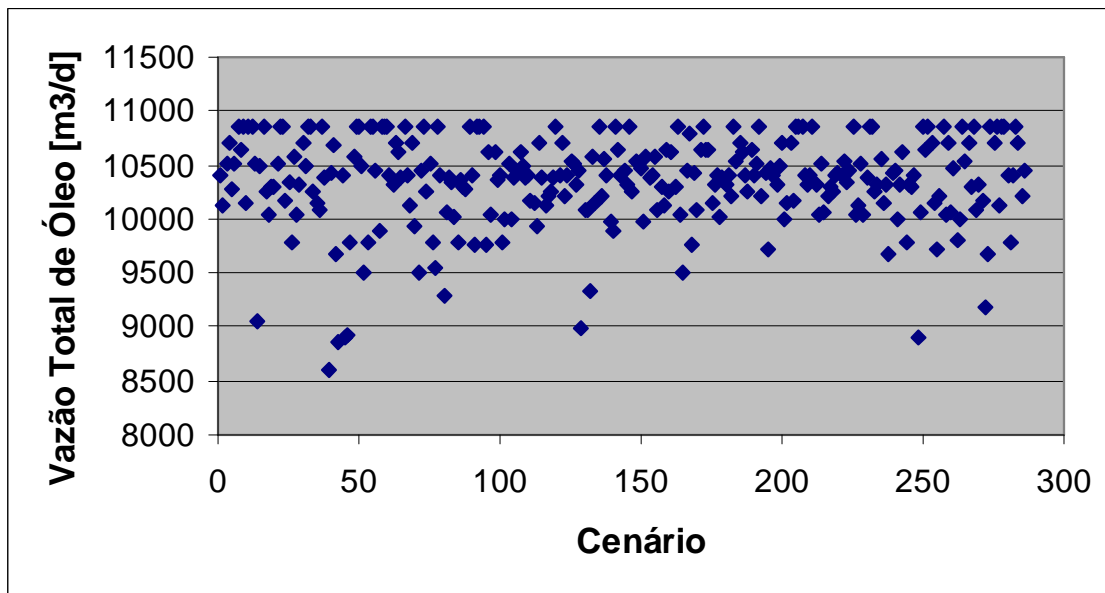


Figura 5.8 – Distribuição da vazão de óleo como função do cenário de estudo.

Como pode ser observado na Figura 5.8, os resultados se encontram dispersos em uma faixa que vai de 8.500 a 11.000 m³/d, com uma concentração maior de pontos entre 10.000 e 11.000 m³/d. Esta característica pode ser melhor observada no histograma da Figura 5.9, onde se observa uma maior frequência de pontos nos blocos que vão de 10.000 a 11.000 m³/d.




Figura 5.9 – Histograma da vazão total de óleo.

Na Figura 5.10, pode-se observar o gráfico da vazão total de *gas lift* como função do cenário. Neste gráfico, observa-se que os resultados se encontram dispersos na faixa que vai de 850.000 a 1.700.000 Nm³/d, com uma concentração maior de pontos entre 1.300.000 e 1.700.000 Nm³/d. O histograma da Figura 5.11 confirma esta característica dos resultados.

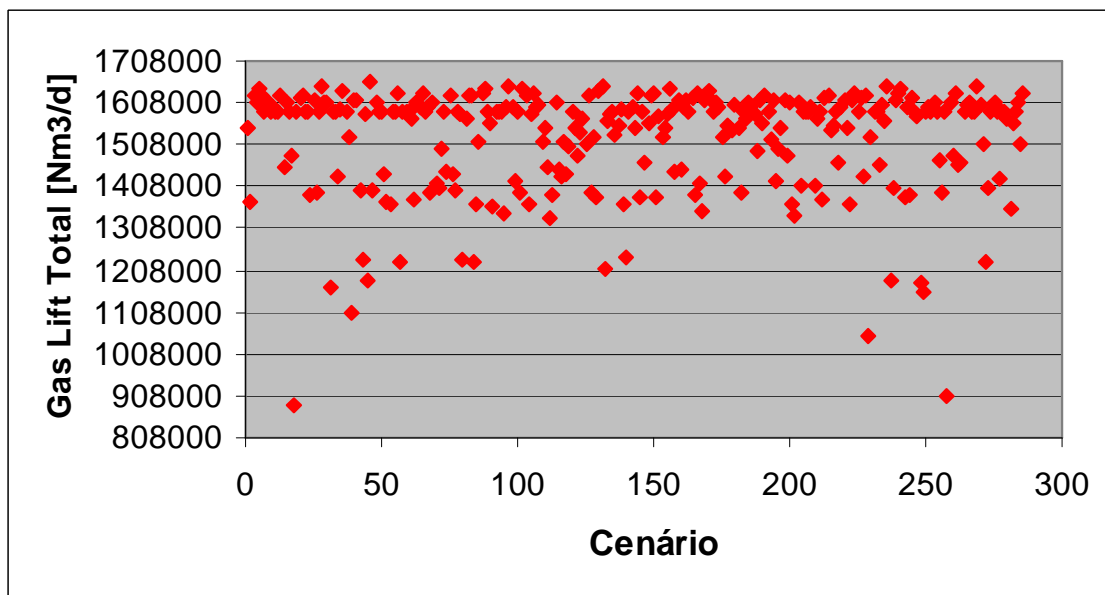


Figura 5.10 – Distribuição da vazão total de *gas lift* como função do cenário.




Figura 5.11 – Histograma da vazão de *gas lift* total.

Estes resultados comprovam a elevada sensibilidade do ponto ótimo de operação em relação às condições iniciais adotadas para o problema, ou seja, a escolha da estimativa inicial é de extrema importância para a eficácia desta estratégia de otimização.

A eficiência computacional da estratégia também é fortemente influenciada pela escolha da estimativa inicial, como pode ser observado nas Figuras 5.12 e 5.13.

Uma análise destes gráficos mostra que o tempo de CPU e o número de iterações variam muito de acordo com a estimativa inicial adotada. Para as análises relacionadas com o tempo de CPU, utilizou-se uma média do tempo de trinta execuções de cada um dos duzentos e oitenta e seis cenários de estudo, visando garantir a robustez do método de análise.




Figura 5.12 – Distribuição do tempo de CPU como função do cenário.

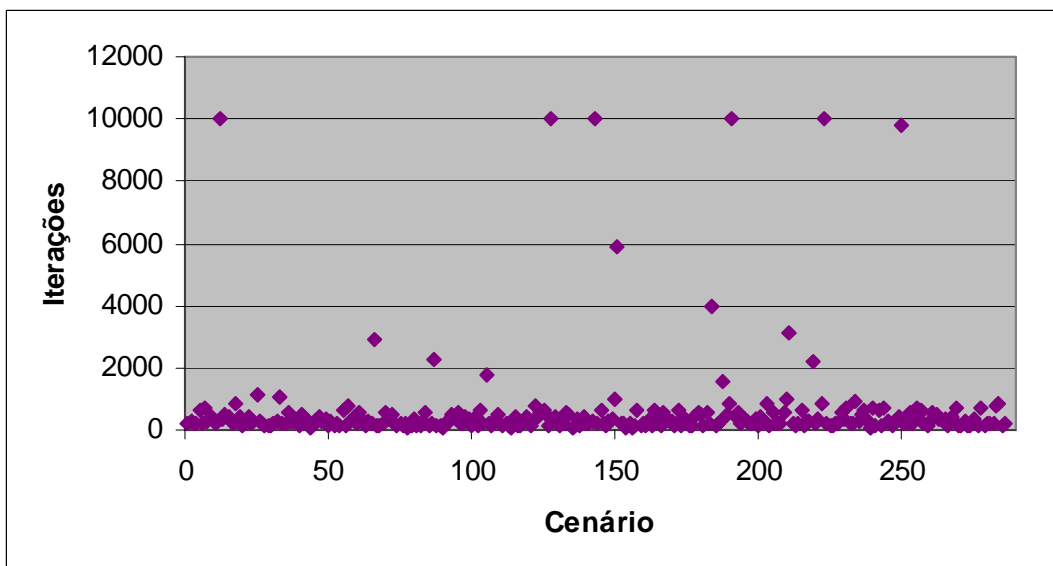


Figura 5.13 – Distribuição do número de iterações como função do cenário.

A Figura 5.14 mostra a relação existente entre o tempo de CPU e o número de iterações utilizado para solucionar o problema. Uma análise deste gráfico demonstra que o tempo de CPU é fortemente influenciado pelo número de iterações, exibindo uma tendência bem definida que só é interrompida nos pontos com 10.000 iterações. Isto pode ser explicado pelo fato do *solver* estar configurado para interromper a otimização quando o número de iterações atingisse o valor de 10.000, ou seja, os valores obtidos nestes pontos não são os valores ótimos do problema.

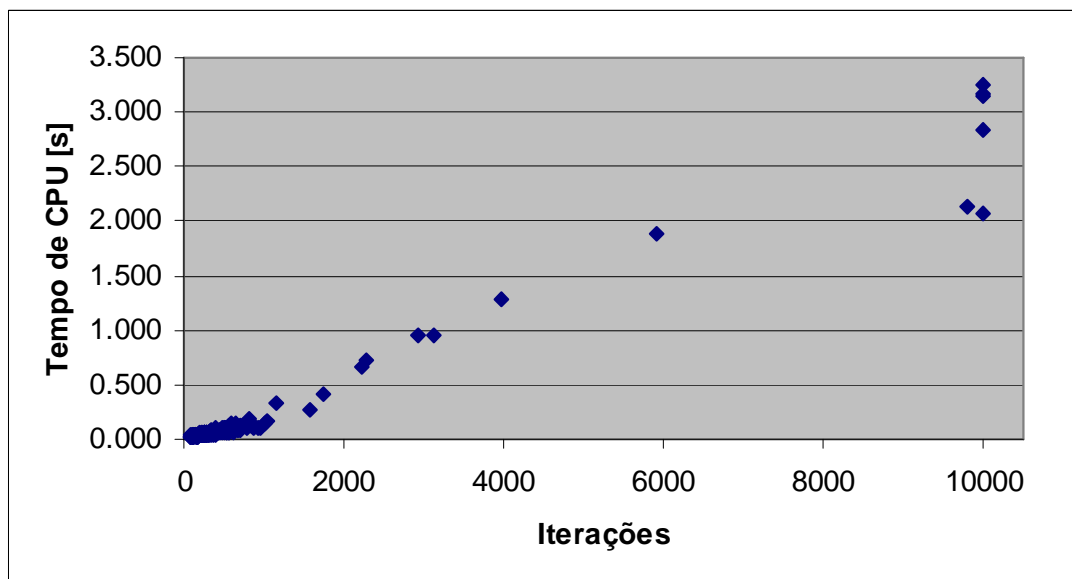


Figura 5.14 – Gráfico do tempo de CPU como função do número de iterações.

5.5 Análise de sensibilidade dos métodos MILP em relação ao número de pontos da curva de eficiência

Conforme foi citado na Seção 5.3 deste trabalho, os resultados das estratégias de otimização baseadas nos métodos de linearização por partes são sensíveis ao número de pontos adotados para representar as funções não-lineares do problema.

Visando avaliar o impacto do número de pontos escolhido no resultado da otimização, realizou-se um teste que consistia na execução do problema de otimização diversas vezes, alterando-se apenas o número de pontos utilizado para representar as curvas de eficiência dos poços.

Para realização deste teste, utilizou-se o modelo baseado no método das estruturas especiais (SSM), porém, sabe-se que os resultados obtidos com os outros métodos em termos de vazão total de óleo e de *gas lift* seriam os mesmos, diferindo apenas no número de iterações e no tempo de CPU.

Na Tabela 5.16, podem-se ver os valores considerados, neste estudo de caso, para as restrições da plataforma.

Tabela 5.16 – Restrições operacionais impostas.

Disponibilidade de gás para <i>gas lift</i>	2.500.000	Nm ³ /d
Capacidade de compressão	2.500.000	Nm ³ /d
Capacidade de tratamento de líquido	16.000	m ³ /d
Capacidade de tratamento de água	6.000	m ³ /d

Com o objetivo de simplificar o problema, optou-se por não restringir a disponibilidade de gás para *gas lift*, o que foi executado igualando-se o valor desta restrição ao da capacidade de compressão da plataforma.

Na Figura 5.15, pode-se observar o impacto do número de pontos utilizados para representar a curva de eficiência na vazão total de óleo e de *gas lift* da plataforma. Uma análise deste gráfico mostra que quanto menor for o número de pontos utilizados para representar a curva, mais grosseira é a aproximação e, conseqüentemente, menor é a vazão total de óleo produzida com um consumo maior de gás, pois a curva não linear é côncava e suas aproximações lineares por partes são subestimativas da mesma.




Figura 5.15 – Vazão total de óleo e de *gas lift* como função do número de pontos utilizados para representar a curva de eficiência.

Na Figura 5.16, pode-se observar a influência do número de pontos utilizados para representar a curva de eficiência no número de iterações e no tempo de CPU utilizados para solucionar o problema.

Como o número de pontos utilizados está relacionado com o número de variáveis de decisão do problema de programação linear inteira mista (MILP), uma redução no mesmo gera uma diminuição no número de iterações e no tempo de CPU demandado para a solução do problema, como pode ser visto na Figura 5.16.

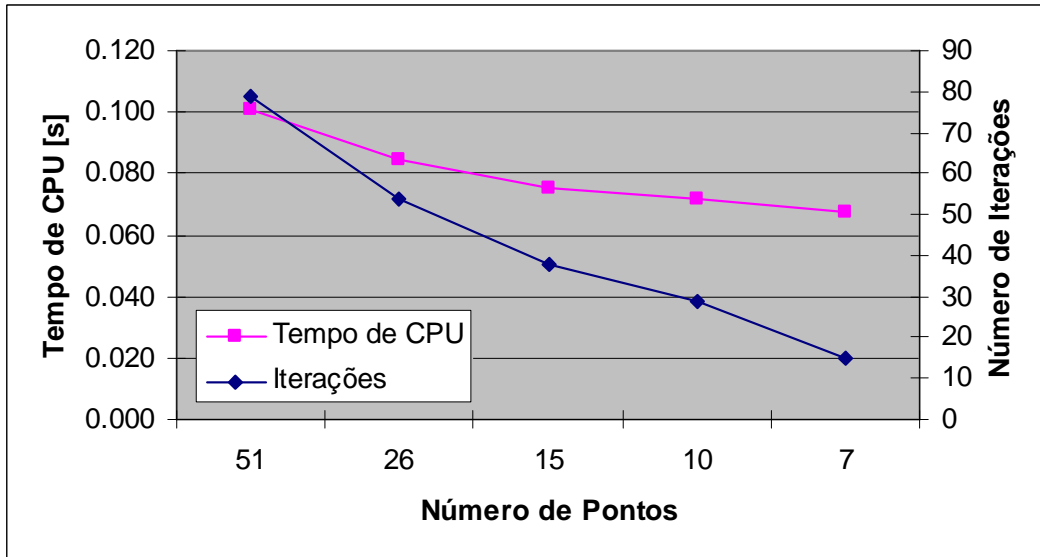


Figura 5.16 – Tempo de CPU e número de iterações como função do número de pontos utilizados para representar a curva de eficiência.

Na Figura 5.17, pode-se observar a relação direta existente entre o número de iterações e o tempo de CPU necessários para solução do problema. Nota-se também uma tendência de crescimento exponencial do tempo de CPU com o aumento do número de iterações, pois este último também aumenta com a dimensão do problema.




Figura 5.17 – Tempo de CPU como função do número de iterações.

5.6 Algoritmo híbrido para solução do problema de otimização da produção de poços que operam com *gas lift* contínuo

Conforme foi mostrado nas Seções 5.3 e 5.4, a estratégia de otimização NLP usando o algoritmo de programação quadrática seqüencial (SQP) se mostrou mais eficiente na solução do problema de otimização da produção de poços que operam com o auxílio do *gas lift* contínuo, porém, os resultados obtidos com esta estratégia são muito sensíveis ao valor adotado como estimativa inicial para o problema.

Já a estratégia de otimização MILP, baseada nos métodos de linearização por partes, não necessita da definição de uma estimativa inicial para o problema, porém, a qualidade dos seus resultados está diretamente relacionada com o número de pontos adotado para representar a curva de eficiência de *gas lift*, ou seja, quanto maior o número de pontos maior é a qualidade dos resultados, porém, maior é o tempo de CPU necessário para solucionar o problema.

Visando obter uma solução eficiente do ponto de vista computacional e que independesse da definição de uma estimativa inicial por parte do usuário do otimizador, propôs-se uma solução híbrida que utiliza um modelo simplificado de programação linear inteira mista (MILP) com o método das estruturas especiais (SSM) para fazer uma primeira estimativa da solução ótima do problema que, posteriormente, é refinada pelo algoritmo de programação quadrática seqüencial (SQP).

O modelo de programação linear inteira mista é chamado de simplificado porque ele utiliza um número menor de pontos para representar as curvas de eficiência, porém, a função objetivo e as restrições utilizadas são as mesmas adotadas pelo algoritmo de programação quadrática seqüencial. Os resultados desta otimização são utilizados como estimativa inicial para o algoritmo de programação quadrática seqüencial que refina de forma eficiente o resultado do problema. A estrutura do algoritmo híbrido proposto pode ser vista no esquema da Figura 5.18.

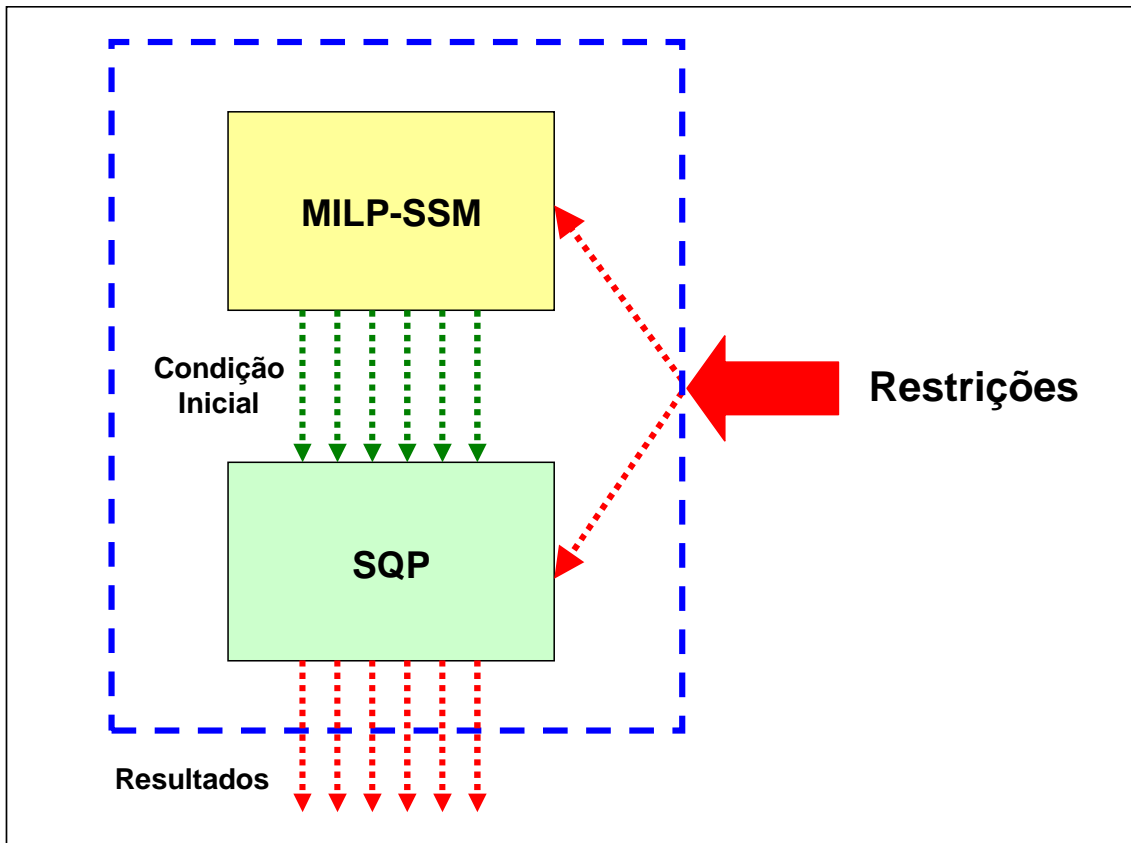


Figura 5.18 – Esquema do algoritmo híbrido proposto.

Com o objetivo de avaliar a robustez e eficiência do algoritmo híbrido proposto, realizou-se um experimento que consistiu na execução da otimização diversas vezes variando-se a capacidade de compressão da plataforma.

Para estabelecer uma base de comparação, executaram-se também, para os mesmos valores de parâmetros e restrições, os modelos baseados nos algoritmos SQP e MILP-SSM. Na Tabela 5.17, podem-se ver os valores considerados, neste estudo de caso, para as restrições da plataforma.

Tabela 5.17 – Restrições operacionais impostas.

Capacidade de tratamento de líquido	16.000	m ³ /d
Capacidade de tratamento de água	6.000	m ³ /d

Com o objetivo de simplificar o problema, optou-se por não restringir a disponibilidade de gás para *gas lift*, o que foi executado igualando-se o valor desta restrição ao da capacidade de compressão da plataforma, para todos os cenários de estudo.

Para o algoritmo MILP-SSM, adotou-se um conjunto de 51 pontos (número de pontos maior do que o utilizado na Seção 5.3) para representar a curva de eficiência de *gas lift* de cada poço. Já para o algoritmo MILP-SSM incorporado na solução híbrida, utilizou-se 20 pontos para representar as curvas.

Para o algoritmo SQP, utilizaram-se as mesmas estimativas iniciais empregadas na Seção 5.3, ou seja, vazões nulas de *gas lift*.

Na Figura 5.19, pode-se observar um gráfico de vazão total de óleo como função da capacidade de compressão da plataforma. Uma análise deste gráfico mostra que para todos os valores de capacidade de compressão, o algoritmo híbrido gerou um melhor resultado em termos de vazão total de óleo produzido. O resultado inferior do SQP pode ser explicado pelo fato do algoritmo ter encontrado um ótimo local.

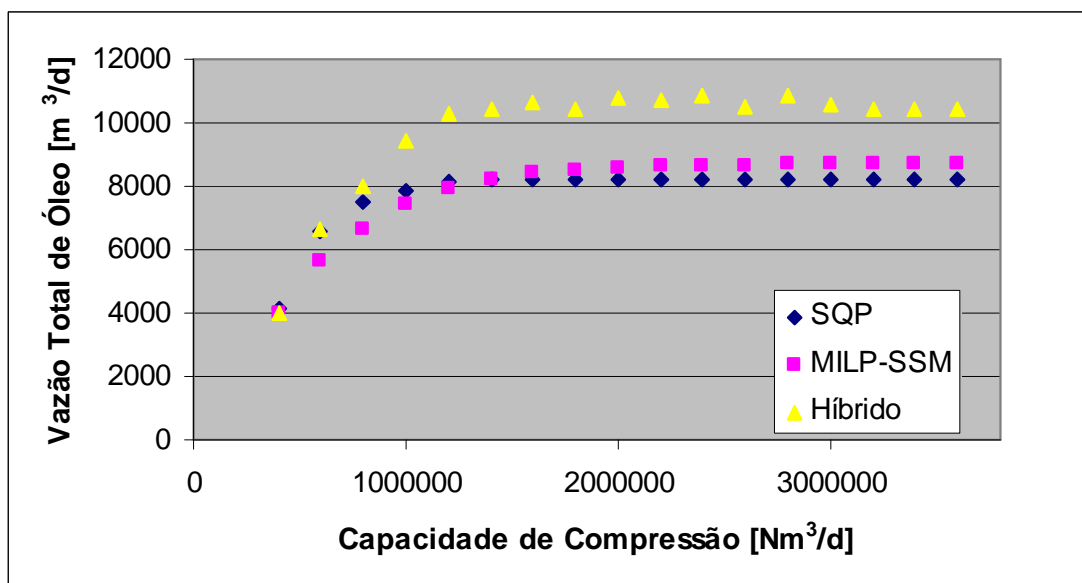


Figura 5.19 – Vazão total de óleo como função da capacidade de compressão da plataforma.

Na Figura 5.20, pode-se observar os resultados obtidos com o algoritmo híbrido em termo de vazão total de *gas lift*.

Uma análise das Figuras 5.19 e 5.20 mostra que o algoritmo híbrido utiliza o gás de forma mais eficiente do que o método MILP-SSM e consegue obter soluções melhores do que o algoritmo SQP para o problema.




Figura 5.20 – Vazão total de *Gas Lift* como função da capacidade de compressão da plataforma.

Já na Figura 5.21, pode-se ver uma comparação entre o tempo computacional demandado pelos três diferentes métodos. O método híbrido demanda um maior tempo computacional por depender da solução de dois problemas de otimização em série. Este tempo poderia ser reduzido de forma significativa através da redução do número de pontos utilizados para representar a curva de eficiência de *gas lift* na parte referente ao algoritmo MILP-SSM.




Figura 5.21 – Tempo de CPU como função da capacidade de compressão da plataforma.

5.7 Otimização da produção em cenário de queda de compressores

Para avaliar o modelo proposto na Seção 4.2 deste trabalho (equações 4.61 a 4.70), considerou-se, inicialmente, um cenário onde existe restrição na capacidade de compressão da plataforma e variou-se o valor do fator de ponderação da função objetivo (w) com o intuito de estudar a sensibilidade do resultado da otimização em relação a este parâmetro ($w = 1$ implica em não ponderar a queima de gás).

A Tabela 5.18 mostra os valores adotados para as restrições operacionais neste experimento.

Tabela 5.18 – Restrições operacionais impostas.

Disponibilidade de gás para <i>gas lift</i>	800.000	Nm ³ /d
Capacidade de compressão	800.000	Nm ³ /d
Capacidade de tratamento de líquido	16.000	m ³ /d
Capacidade de tratamento de água	6.000	m ³ /d
Limite máximo de queima	1.000.000	Nm ³ /d

Na Figura 5.22, pode-se ver a frente de Pareto resultante deste experimento, onde os pontos da curva representam o resultado da otimização para um valor ou conjunto de valores do fator de ponderação.

Uma análise deste gráfico nos mostra que, em um cenário com baixa capacidade compressão, um aumento no valor da queima resulta em um aumento de produção, porém, valores elevados de queima não são desejados devido à necessidade de honrar os limites estabelecidos pelos órgãos ambientais. Portanto, a frente de Pareto é uma ferramenta útil para auxiliar os engenheiros na escolha de uma solução que resulte no melhor compromisso entre a produção total de óleo e a queima de gás admissível para o cenário de estudo.




Figura 5.22 – Vazão total de óleo como função da queima de gás admissível para diferentes valores do fator de ponderação (Frente de Pareto).

Outro experimento que foi realizado com o objetivo de avaliar o modelo desenvolvido consistiu na variação da capacidade de compressão da plataforma em conjunto com a variação do fator de ponderação. Os resultados deste experimento podem ser vistos nas Figuras 5.23 e 5.24. Uma análise da Figura 5.23 mostra que quando maior for o valor do fator de ponderação, maior é a queima sugerida pelo otimizador, mesmo para valores elevados de capacidade de compressão. A situação limite ocorre quando o fator de ponderação é igual a 1, cenário no qual o otimizador recomenda uma queima igual ao limite máximo estabelecido, independentemente da capacidade de compressão considerada.

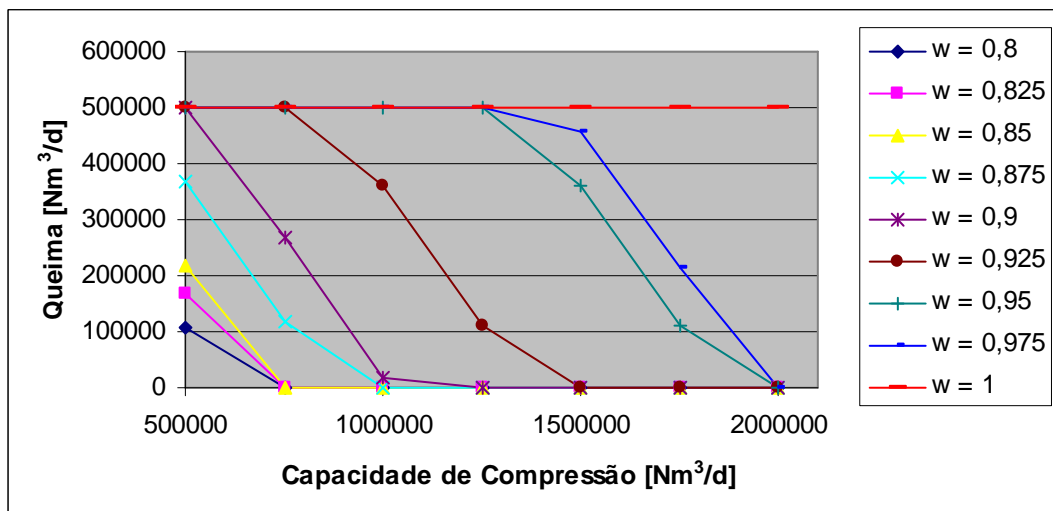


Figura 5.23 – Queima como função da capacidade de compressão e do fator de ponderação.

Na Figura 5.24, podem-se ver os valores da produção total de óleo da plataforma para diferentes valores de capacidade de compressão e fator de ponderação que, neste caso, define os valores da queima admissível. As curvas para valores de $w < 1$ apresentam uma mudança de comportamento no momento em que a vazão de gás para queima é reduzida a zero, conforme mostra a Figura 5.23, deixando de penalizar a função objetivo e permitindo um maior aumento da produção.




Figura 5.24 – Vazão total de óleo como função da capacidade de compressão e do fator de ponderação.

5.8 Otimização da produção considerando a pressão à montante da válvula *choke* dos poços

Com o objetivo de avaliar o modelo de otimização que considera a pressão na cabeça como uma das variáveis de decisão (equações 4.71 a 4.80), realizou-se um teste que consistiu na variação da capacidade de tratamento da água produzida com o intuito de estudar o impacto nas variáveis de decisão do problema. Na Tabela 5.19, podem-se ver os valores das restrições operacionais adotados neste experimento.

Tabela 5.19 – Restrições operacionais impostas.

Disponibilidade de gás para <i>gas lift</i>	2.000.000	Nm ³ /d
Capacidade de compressão	2.000.000	Nm ³ /d
Capacidade de tratamento de líquido	16.000	m ³ /d
Limite máximo de queima	500.000	Nm ³ /d

Na Figura 5.25, pode-se ver um gráfico da vazão total de óleo da plataforma como função da capacidade de tratamento de água. A linha vertical tracejada indica o momento em que a restrição referente à capacidade de tratamento de água se tornou inativa.




Figura 5.25 – Vazão total de óleo como função da capacidade de tratamento de água.

As Figuras 5.26 a 5.28 mostram o impacto da variação da capacidade de tratamento de água na vazão de *gas lift*, pressão a montante do *choke* e vazão de óleo de cada poço produtor.

Uma análise destes gráficos mostra que o otimizador sugeriu o fechamento dos poços 4, 10 e 11 que são os poços com maior BSW. Na Figura 5.28, valores de pressão a montante do *choke* de produção iguais a zero indicam que o poço está fechado. Já valores iguais a 10 kgf/cm² indicam que o *choke* de produção está completamente aberto e a pressão a montante é praticamente igual à pressão do separador de produção.

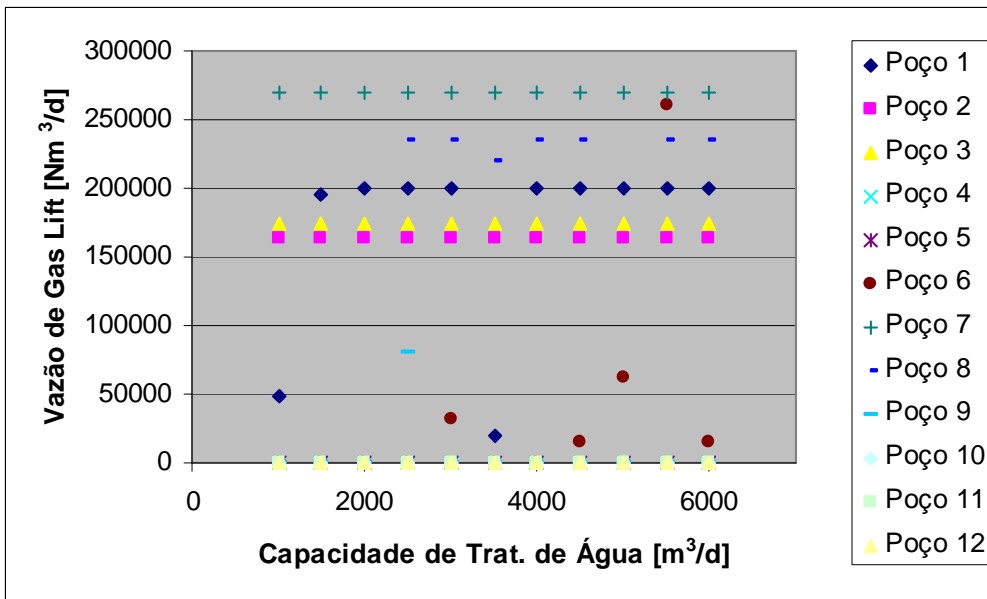


Figura 5.26 – Vazão de *gas lift* de cada poço como função da capacidade de tratamento de água.




Figura 5.27 – Vazão de óleo de cada poço como função da capacidade de tratamento de água.

Na Figura 5.28, pode-se ver que o otimizador alterou significativamente a pressão a montante do *choke* dos poços 6 e 12 que são poços surgentes de alta vazão.

Uma análise da Figura 5.25 mostra que apesar da restrição referente à capacidade de tratamento de água ter se tornado inativa para valores superiores a 4500 m³/d, alguns poços continuaram fechados. Isto pode ser explicado pela Figura 5.29 que

mostra que a restrição de capacidade de tratamento de líquido se torna ativa a partir desta vazão.




Figura 5.28 – Pressão a montante do *choke* de cada poço como função da capacidade de tratamento de água.




Figura 5.29 – Vazão total de líquido como função da capacidade de tratamento de água.

5.9 Análise de Incerteza

Para analisar o impacto da incerteza existente em alguns parâmetros do modelo (tais como o BSW, RGO, IP e pressão estática dos poços) no resultado da otimização, desenvolveu-se um procedimento que consistiu na modelagem da incerteza destes

parâmetros, considerando que ela segue um modelo de distribuição de probabilidade conhecido (Ex.: Normal, Weibull, etc.).

De posse das funções densidade de probabilidade dos parâmetros, geraram-se aleatoriamente um número significativo de conjuntos de amostras do parâmetro de estudo para os poços.

Com estes conjuntos, geraram-se as curvas de eficiência de *gas lift* dos poços, através do uso do simulador e executou-se a otimização, com o objetivo de calcular o ponto ótimo de operação em cada cenário. Os resultados da otimização foram avaliados com o objetivo de quantificar o impacto da incerteza nos resultados da otimização.

Um fluxograma do procedimento adotado pode ser visto na Figura 5.30.

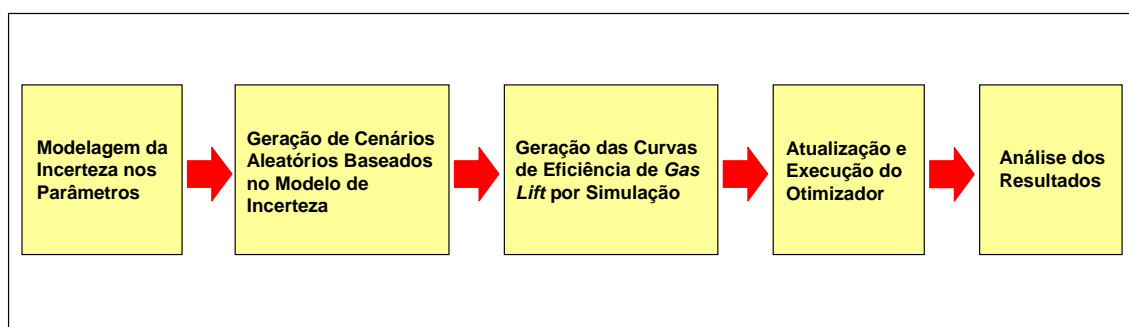


Figura 5.30 – Fluxograma do procedimento de análise de incerteza.

Para automatizar o procedimento de análise de incerteza, utilizou-se um *software* chamado Pipe-It (desenvolvido pela empresa norueguesa PERA S.A) que foi responsável pela integração do simulador de escoamento multifásico com a estratégia de otimização implementada no GAMS e pela execução automática dos cenários de estudo.

Apesar do procedimento descrito acima ser aplicável a qualquer parâmetro do modelo, optou-se por utilizar neste estudo de caso o BSW dos poços.

Uma análise dos valores de BSW medidos diariamente nos poços, a partir da análise laboratorial de amostras do líquido produzido, mostrou que o comportamento deste parâmetro pode ser representado satisfatoriamente por uma distribuição Normal com média e desvio padrão determinados a partir dos dados de campo.

O BSW influencia, principalmente, no comportamento da curva de eficiência de *gas lift* que é gerada a partir de um simulador de escoamento multifásico, conforme explicado na Seção 4.1.4 deste trabalho.

De posse das funções densidade de probabilidade do BSW dos poços, geraram-se aleatoriamente conjuntos de amostras, sendo que cada conjunto possuía um valor aleatório do parâmetro de estudo por poço.

Com estes conjuntos de dados, geraram-se as curvas de eficiência de *gas lift* dos poços, através do uso do simulador MARLIM II e executou-se a otimização, com o objetivo de calcular o ponto ótimo de operação em cada cenário.

Com o objetivo de simplificar o procedimento de teste, optou-se por utilizar apenas os seis primeiros poços da Tabela 5.1 (Seção 5.1 deste trabalho) na análise da incerteza e, visando manter a consistência do cenário de estudo, reduziram-se também as capacidades da plataforma, conforme pode ser visto na Tabela 5.20.

Tabela 5.20 – Restrições operacionais impostas.

Disponibilidade de gás para <i>gas lift</i>	1.000.000	Nm ³ /d
Capacidade de compressão	1.000.000	Nm ³ /d
Capacidade de tratamento de líquido	8.000	m ³ /d
Capacidade de Tratamento de Água	3.000	
Limite máximo de queima	0	Nm ³ /d

Nas Figuras 5.31 a 5.36, podem-se ver os histogramas do parâmetro BSW dos poços que foram construídos a partir das amostras geradas aleatoriamente, seguindo uma distribuição normal com uma média e desvio padrão baseados nos dados de campo obtidos por amostragem diária do fluido dos poços para análise em laboratório.




Figura 5.31 – Histograma do BSW do Poço 1.




Figura 5.32 – Histograma do BSW do Poço 2.




Figura 5.33 – Histograma do BSW do Poço 3.




Figura 5.34 – Histograma do BSW do Poço 4.




Figura 5.35 – Histograma do BSW do Poço 5.




Figura 5.36 – Histograma do BSW do Poço 6.

Conforme descrito anteriormente, os cem conjuntos de amostras foram utilizados para variar o BSW dos modelos dos poços no simulador de escoamento multifásico e, após a atualização das curvas de eficiência no otimizador, executou-se a otimização (algoritmo MILP-SSM), obtendo-se o histograma da produção total de óleo da plataforma e do total de gás utilizado para *gas lift*, como pode ser visto nas Figuras 5.37 e 5.38.




Figura 5.37 – Histograma da produção total de óleo da plataforma.




Figura 5.38 – Histograma do consumo total de *gas lift* dos poços.

A Tabela 5.21 mostra os valores da média e do desvio padrão calculados para o BSW dos poços (dados de entrada do procedimento). Já a Tabela 5.22 mostra a média e o desvio padrão da vazão total de óleo produzida e do consumo total de gás para *gas lift* obtidos a partir dos resultados da otimização.

Tabela 5.21 – Estatísticas do BSW dos poços.

	Média [%]	Desvio Padrão
Poço 1	30	3,69
Poço 2	17	4,87
Poço 3	7	1,80
Poço 4	68	6,08
Poço 5	52	8,30
Poço 6	36	3,67

Tabela 5.22 – Estatísticas dos resultados da otimização.

	Média	Desvio Padrão
Vazão Total de Óleo [m ³ /d]	4.759,62	320,84
Vazão Total de <i>Gas Lift</i> [Nm ³ /d]	571.788,90	28.476,38

Com base nos resultados da Tabela 5.22 é possível estabelecer um intervalo de confiança no qual o ponto ótimo de operação estará localizado, considerando o nível de incerteza nos parâmetros de entrada. Neste caso, pode-se afirmar com 99,73% (três desvios padrão) de certeza que a máxima produção de óleo da plataforma estará na faixa entre 3.797 e 5.722 m³/d.

Já o consumo ótimo de gás para *gas lift* estará com 99,73% de certeza na faixa entre 486.361 e 657.217 Nm³/d.

Este grande intervalo causado pela incerteza nos parâmetros do modelo justifica a realização de melhorias do processo de medição, visando garantir a redução da incerteza nos valores dos parâmetros, bem como o desenvolvimento e aplicações de estratégias de controle avançado e otimização em tempo real que ficam continuamente tentando otimizar o processo dentro de uma faixa pré-estabelecida pelos engenheiros e operadores.

As estatísticas dos resultados de vazão de óleo e consumo de *gas lift* por poço podem ser vistos nas Tabelas 5.23 e 5.24, respectivamente.

Tabela 5.23 – Estatísticas da vazão de óleo produzida por poço.

	Média [m ³ /d]	Desvio Padrão
Poço 1	593,67	88,61
Poço 2	1.039,75	74,17
Poço 3	446,74	15,51
Poço 4	216,86	227,62
Poço 5	1.042,15	317,65
Poço 6	1.420,44	133,79

Tabela 5.24 – Estatísticas do consumo de *gas lift* por poço.

	Média [Nm ³ /d]	Desvio Padrão
Poço 1	86.605,36	24.690
Poço 2	34.142	22.494
Poço 3	123.681	20.225
Poço 4	19.311	28.647
Poço 5	208.298	49.636
Poço 6	99.751	29.388

A mesma estratégia empregada para a definição do intervalo de confiança dos resultados da plataforma poderia ser aplicada individualmente aos poços.

Capítulo 6

Conclusões e Sugestões para Trabalhos Futuros

Neste trabalho, compararam-se dois modelos para o problema de otimização de *gas lift*, sendo que um considerou uma função objetivo operacional e o outro uma econômica. Concluiu-se que o uso de uma função objetivo operacional pode gerar perdas financeiras significativas na operação de uma plataforma, por não levar em conta os custos associados ao tratamento dos fluidos gerados no processo, sendo assim, recomenda-se o uso da função objetivo econômica.

Mostrou-se também que o uso de uma função de regularização em conjunto com a função proposta por Alarcón et al. (2002) modela com precisão as curvas de eficiência de *gas lift* de poços que possuem uma vazão de ativação.

Compararam-se os resultados obtidos com a aplicação de diferentes algoritmos de otimização ao problema (SQP e MILP + Linearização por partes), concluindo-se que, apesar de todos os algoritmos testados solucionarem o problema de forma satisfatória, o SQP apresentou um melhor resultado geral.

Adicionalmente, mostrou-se que a estratégia proposta utilizando o algoritmo SQP é muito sensível ao valor da estimativa inicial escolhida para o problema, o que motivou a proposição de uma estratégia híbrida que utiliza o algoritmo MILP-SSM para definir a estimativa inicial para o SQP, que refina a solução buscando o ponto ótimo. Os resultados da estratégia híbrida foram superiores aos obtidos com as estratégias originais.

Um modelo para otimização da produção em cenários com restrições severas na capacidade de compressão foi proposto, apresentado resultados satisfatórios. Este modelo inclui uma função multiobjetivo que auxilia o engenheiro na definição do melhor compromisso entre a produção total de óleo e a queima de gás admissível no processo.

Uma estratégia de otimização utilizando a pressão à montante da válvula *choke* de produção como variável de decisão foi proposta, apresentando ganhos significativos, principalmente em cenários com a presença de um número elevado de poços surgentes em que a variação do *gas lift* passa a não ser suficiente para a otimização da produção.

Por fim, um procedimento para avaliação do impacto da incerteza nos parâmetros do modelo de otimização foi proposto e o impacto da incerteza no valor do BSW dos poços foi quantificado como estudo de caso. Os resultados da análise mostraram que a influência da incerteza é significativa e não pode ser ignorada no processo de otimização da produção. Este estudo também comprovou a importância de iniciativas relacionadas com a melhoria da qualidade das medições, reduzindo a incerteza associada, bem como da aplicação de técnicas de controle avançado e otimização em tempo real que buscam continuamente a maximização da produção variando o processo dentro de faixas pré-estabelecidas pelos engenheiros e operadores.

Uma oportunidade identificada para ser desenvolvida em trabalhos futuros consiste na incorporação da incerteza dos parâmetros no modelo de otimização, através da aplicação de técnicas de otimização estocástica.

Referências Bibliográficas

ALARCÓN, G. A.; TORRES, C. F.; GÓMEZ, L. E. Global optimization of gas allocation to a group of wells in artificial lift using nonlinear constrained programming. *Journal of Energy Resources Technology*, v. 124, p. 262-268, 2002.

ARNOLD, K.; STEWART, M. Surface production operations: design of gas-handling systems and facilities. V.2, 2 ed., Massachusetts, Gulf Professional Publishing, 1999. ISBN-13 978-0-88415-822-6.

ARNOLD, K.; STEWART, M. Surface production operations: design of oil handling systems and facilities. V.1, 3 ed., Massachusetts, Gulf Professional Publishing, 2008. ISBN 978-0-7506-7853-7.

BIEGLER, L. T. Nonlinear programming concepts, algorithms and applications to chemical processes. Society for Industrial and Applied Mathematics (SIAM), Filadélfia, 2010. ISBN 978-0-898717-02-0.

BIEKER, H. P.; SLUPPHAUG, O.; JOHANSEN, T. A. Real-Time production optimization of oil and gas production systems: a technology survey. *SPE Intelligent Energy Conference and Exhibition*, Amsterdam, Holanda, 2007.

BOYD, S.; VANDENBERGHE, L. Convex optimization. Cambridge University Press, Reino Unido, 2004. ISBN 978-0-521-83378-3.

BUITRAGO, S.; RODRÍGUEZ, E.; ESPIN, D. Global optimization techniques in gas allocation for continuous flow gas lift systems. *SPE Gas Technology Conference*, Alberta, Canada, 1996; SPE 35616.

CAMPONOGARA, E.; NAKASHIMA, P. H. R. Solving a gas-lift optimization problem by dynamic programming. *European Journal of Operational Research*, 174, p. 1220-1246, 2005.

CAMPOS, M. C. M. M.; TEIXEIRA, A. F. Os benefícios e desafios da aplicação de técnicas de controle avançado e otimização em tempo real em unidades marítimas de produção. VI Congresso Rio Automação, Rio de Janeiro, Brasil, 2011. IBP685_11.

CAMPOS, M. C. M. M.; TEIXEIRA, H. C. G. Controles típicos de equipamentos e processos industriais. Editora Edgard Blucher, 2006. ISBN 85-212-0398-5.

ECONOMIDES, M. J.; WATTERS, L. T. e DUNN-NORMAN, S. Petroleum well construction. Editora John Wiley and Sons, 1998. ISBN 0-471-96938-9.

EDGAR, T. F.; HIMMELBLAU, D. M.; LASDON, L. S. Optimization of chemical processes, second edition. McGraw-Hill, 2001. ISBN 0-07-039359-1.

FLOUDAS, C. A. Nonlinear and mixed-integer optimization: fundamentals and applications. Editora Oxford University Press, 1995. ISBN 0-19-510056-5.

GOLAN, M. e WHITSON, C. H. Well performance. Editora Kluwer Academic Publishers, 1986. ISBN 9-0277-2283-8.

GUNNERUD, V. On decomposition and piecewise linearization in petroleum production optimization. PHD Thesis, NTNU, 2011.

KANU, E. P.; MACH, J.; BROWN, K. E. Economic approach to oil production and gas allocation in continuous gas lift. *Journal of Petroleum Technology*, p. 1887-1892, 1981.

KEHA, A. B.; FARIAS, I. R.; NEMHAUSER, G. L. Models for representing piecewise linear cost functions. *Operations Research Letters*, v. 32, p. 44-48, 2004.

LO, K. K. Optimum lift-gas allocation under multiple production constraints. *SPE Journal*, SPE 26017, 1992.

MARTÍNEZ, E. R.; MORENO, W. J.; MORENO, J. A.; MAGGIOLO, R. Application of genetic algorithm on the distribution of gas lift injection. *III Latin America/Caribbean Petroleum Engineering Conference*, Buenos Aires, Argentina, 1994. SPE 26993.

MISENER, R.; GOUNARIS, C. E.; FLOUDAS, C. A. Global optimization of gas lifting operations: a comparative study of piecewise linear formulations. *Ind. Eng. Chem. Res.*, v. 48, n. 13, p. 6098-6104, 2009.

NISHIKIORI, N. Gas allocation optimization for continuous flow gas lift systems. M. S. Thesis, University of Tulsa, 1989.

NUNES, G. C.; MEDEIROS, J. L.; ARAÚJO, O. Q. F. Modelagem e controle na produção de petróleo: aplicações em MATLAB. Editora Edgard Blucher, 2010.

RASHID, K.; DEMIREL, S.; Couet, B. Gas-lift optimization with choke control using a mixed-integer nonlinear formulation. *Ind. Eng. Chem. Res.*, v. 50, p. 2971-2980, 2011.

REDDEN, J. D.; SHERMAN, A. G.; BLANN, J. R. Optimizing gas-lift systems. SPE 5150, 1974.

REIDER, C. A. Unidade de Compressão de 3 Estágios & Fluxograma Essencial de Plataforma. Apresentação na UFSC, 2007.

SACHDEVA, R., SCHIMIDT, Z., BRILL, J. P. Two-phase flow through chokes. SPE Annual Technical Conference and Exhibition, New Orleans, USA, 1986. SPE 15657.

SOUZA FILHO, J. E. Processamento primário de fluidos: separação e tratamento. Apostila (Curso de formação em engenharia de petróleo da Petrobras), 2006.

TAKÁCS, G. Gas lift manual. Editora Pennwell, 2005. ISBN 0-87814-805-1.

THOMAS, J. E. Fundamentos de engenharia de petróleo. Rio de Janeiro, Editora Interciência, 2001. ISBN 85-7193-046-5.

VEROTTI FILHO, C. Separação, tratamento e processamento do gás natural. Apostila (Curso de formação em engenharia de petróleo da Petrobras), 2006.

WANG, P.; LITVAK, M.; AZIZ, K. Optimization of production operations in petroleum fields. *SPE Annual Technical Conference and Exhibition*, Texas, Estados Unidos da América, 2002. SPE 77658.

ZANIN, A. C. Implementação industrial de um otimizador em tempo real. Tese de doutorado, USP, 2001.

ZHENG-GANG, X.; HERFJORD, H. J.; RAMSTAD, H. J. Economical distribution of gas in a continuous gas-lift system subject to variable cost and system constraints. *The Journal of Canadian Petroleum Technology*, v. 29, n. 5, 1990.