



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

**TÉCNICAS DE OTIMIZAÇÃO POR APROXIMAÇÃO
SEQUENCIAL APLICADAS A AJUSTE DE HISTÓRICO NA
SIMULAÇÃO DE RESERVATÓRIOS**

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL
DE PERNAMBUCO PARA OBTENÇÃO DE GRAU DE MESTRE
EM ENGENHARIA MECÂNICA

ANDRÉA LEITE DO CARMO

Recife, Agosto de 2010

Técnicas de Otimização por Aproximação Sequencial Aplicadas a Ajuste de Histórico na Simulação de Reser- vatórios

Andréa Leite do Carmo

Dissertação de Mestrado submetida ao Corpo Docente do Curso de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Pernambuco, como parte dos requisitos necessários à obtenção do grau de Mestre em Ciências em Engenharia Mecânica.

Área de Concentração: Mecânica Computacional

Ramiro Brito Willmersdorf, D.Sc
Orientador
Silvana Maria Bastos Afonso
Co-orientadora

Recife, Pernambuco, Brasil
Andréa Leite do Carmo, Agosto de 2010

Catálogo na fonte
Bibliotecário Marcos Aurélio Soares da Silva, CRB-4 / 1175

C287t Carmo, Andréa Leite do.
Técnicas de otimização por aproximação sequencial aplicadas a ajuste de histórico na simulação de reservatórios / Andréa Leite do Carmo. - Recife: O Autor, 2010.
xiv, 111 folhas, il., gráfs., tabs.

Orientador: Prof^o Dr.. Ramiro Brito Willmersdorf.
Dissertação (Mestrado) – Universidade Federal de Pernambuco.
CTG. Programa de Pós-Graduação em Engenharia Mecânica, 2010.
Inclui Referências.

1. Engenharia Mecânica. 2.Otimização Aproximada Sequencial (ASO). 3.Simulação Numérica. 4. Simulação de Reservatórios. I. Willmersdorf, Ramiro Brito (orientador). II. Título.

621 CDD (22. ed.) UFPE
BCTG/2011-075

"TÉCNICAS DE OTIMIZAÇÃO POR APROXIMAÇÃO SEQUENCIAL APLICADAS
A AJUSTE DE HISTÓRICO".

ANDRÉA LEITE DO CARMO

ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA OBTENÇÃO DO
TÍTULO DE MESTRE EM ENGENHARIA MECÂNICA

ÁREA DE CONCENTRAÇÃO: MECÂNICA COMPUTACIONAL
APROVADA EM SUA FORMA FINAL PELO
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA/CTG/EEP/UFPE



Prof. Dr. RAMIRO BRITO WILLMERSDORF
ORIENTADOR/PRESIDENTE



Prof. Dr. SEVERINO LEOPOLDINO URTIGA FILHO
COORDENADOR DO CURSO

BANCA EXAMINADORA:



Prof. Dr. RAMIRO BRITO WILLMERSDORF (UFPE)



Prof. Dr. SILVANA MARIA BASTOS AFONSO (UFPE)



Prof. Dr. PAULO ROBERTO MACIEL LYRA (UFPE)



Prof. Dr. BERNARDO HOROWITZ (UFPE)

Agradecimentos

Aos professores Ramiro Brito Willmersdorf e Silvana Afonso pelos ensinamentos transmitidos e pela sua valiosa orientação para a realização desta pesquisa.

A minha filha Júlia Maria, pela compreensão que os momentos de ausência, são necessários para o meu crescimento profissional e pessoal.

A meus pais por me prepararem para a vida com muito amor e sacrifício, me ensinando o caminho do bem e da verdade.

A minha irmã pelo amor e a força.

A todos os meus amigos por sempre acreditarem nas minhas empreitadas, que me dão tanta força em todos os momentos.

A minha amiga de curso Jane, que me motivou neste período, e dividiu comigo seus conhecimentos em assuntos que não são de minha área de atuação.

Aos amigos da UFPE, Gisele, Helder, Dásio, Jeferson, Leonardo, entre outros pelo convívio e ajuda no período do curso.

E a DEUS por guiar sempre o meu caminho.

Resumo

O principal problema do uso de otimização com simulações em projetos de engenharia de petróleo se deve a extensiva demanda computacional requerida, devido principalmente à grande quantidade de simulações numéricas realizadas durante o processo. Neste trabalho é apresentada uma alternativa para superar tal dificuldade, utilizando-se funções substitutas - através da construção de modelos substitutos (metamodelos) - que são menos custosas de serem realizadas, no qual amenizam o esforço computacional gerado durante o processo de otimização existente para esta classe de aplicação. Desta maneira, torna-se viável a utilização de um algoritmo de otimização, sem a necessidade de executar o simulador numérico de uma forma intensiva.

A simulação numérica permite a obtenção de uma previsão do comportamento do reservatório com base em um modelo numérico, previamente construído a partir de diversos parâmetros gerados durante a caracterização do campo de petróleo.

Após a construção de um modelo numérico a sua validação com histórico de produção é feita através do ajuste de histórico onde o modelo de reservatório é corrigido para que os resultados obtidos pelo simulador reproduzam os resultados observados, sendo através desse processo gerado uma boa caracterização de reservatório de petróleo e conseqüentemente uma boa previsão de produção.

Isto posto, este trabalho buscou desenvolver uma metodologia para automatizar o processo de ajuste de histórico de produção por um ajuste assistido, em simulação numérica de reservatório de petróleo, através da minimização matemática de uma função-objetivo utilizando-se de um método de otimização baseado na estratégia de Otimização Aproximada Sequencial (SAO).

Para o desenvolvimento do sistema foram implementadas rotinas em OCTAVE, posteriormente integradas ao DAKOTA e ao simulador IMEX, permitindo o funcionamento da metodologia através da troca de dados entre esses programas.

Como resultado desse trabalho obteve-se, através da simulação numérica de reservatória, dados para avaliar o processo de ajuste de histórico, utilizando-se de técnicas de otimização por aproximação sequencial, visando encontrar um modelo ajustado que será utilizado para realizar previsões futuras do reservatório, provendo subsídios para uma exploração mais confiável.

Palavras-chaves: Ajuste de Histórico, Otimização por Aproximação Sequencial, Simulação de Reservatórios

Abstract

The main problem about using optimization with simulation in projects of oil engineering is the extensive computational processing required, mainly due to large amount of numerical simulations carried out during the process. In this work is proposed an alternative to overcome that difficulty, using the replacement functions - through the construction of surrogate models (metamodels) - that are less costly to be carried out and ease or eliminate the shortcomings of optimization methods that exist for this application class. Thus, it becomes feasible to use an optimization algorithm without the need to run the simulator numerically-intensive.

The numerical simulation allows obtaining a prediction of the reservoir's behavior based on a numerical model, previously constructed from a variety of parameters generated during the characterization of the oil field.

After the construction of a numerical model its validation with production history is made by history matching of the reservoir where the model is corrected for the results obtained by the simulator to reproduce the observed results being achieved through this process of reproduction of sound reservoir characterization of oil and therefore a good prediction of production.

That said, this work intended to develop a methodology to automate the process of history matching of production assisted by an adjustment, in numerical simulation of oil reservoir, by minimizing a mathematical objective-function using an optimization method based the strategy for Sequential Approximate Optimization (SAO).

To develop the system were implemented routines in OCTAVE, which were later integrated with DAKOTA and IMEX simulator, allowing the functioning of the methodology through the exchange of data between these programs.

As result of this work were obtained, through numerical simulation of reservoir, data to evaluate the process of history matching, using techniques for sequential approximate optimization, aiming to find a adjusted model that will be used

for the reservoir's future forecasts, providing subsidies for a more reliable exploitation.

Key-words: History Matching, Sequential Approximate Optimization, Reservoir Simulation

Lista de Símbolos

Romanos

Escalares:

$\hat{f}(\mathbf{x})$	Função aproximada
$f(\mathbf{x})$	Função-objetivo
i, j	Índices das coordenadas dos vetores
k	Índice das coordenadas dos vetores
$COP^{Observado}$	Dados observados da série de dados
$COP^{Calculado}$	Dados Calculados da série de dados
$\mathcal{L}(\mathbf{x}, \lambda)$	Função Lagrangeana
m	Tamanho da amostra
n	Número das variáveis de projeto; número de intervalos da variável aleatório
p, q	Tamanho das restrições de desigualdade e igualdade
z	Número da iteração SAO
tol	Tolerância da estratégia SAO
n_c	Número de coeficiente
x_1, x_2	Coordenadas dos pontos x
y_1, y_2	Coordenadas dos pontos y
b_1, b_2	Comprimentos de correlação
N_r	Número de realizações

Vetores:

\mathbf{d}	Direção de busca
$\mathbf{g}(\mathbf{x})$	Função restrição de desigualdade

$\mathbf{h}(\mathbf{x})$	Função restrição de igualdade
$\hat{\mathbf{g}}(\mathbf{x})$	Função aproximada da restrição de desigualdade
$\hat{\mathbf{h}}(\mathbf{x})$	Função aproximada da restrição de igualdade
\mathbf{u}	Deslocamento
\mathbf{x}	Variáveis de projeto
$\mathbf{x}_0, \mathbf{x}^*$	Variáveis de projeto no ponto inicial e ótimo de projeto, respectivamente
\mathbf{x}_c	Variáveis de projeto no ponto central da região de confiança
$\mathbf{x}^L, \mathbf{x}^U$	Limites inferiores e superiores das variáveis de projeto, respectivamente
$\mathbf{N}(\mathbf{x})$	Polinômio de regressão
$\mathbf{c}_0, \mathbf{c}_i, \mathbf{c}_j, \mathbf{c}_k$	Coefficientes polinomiais
∇f	Derivada da função objetivo com relação às variáveis de projeto

Matrizes

\mathbf{K}	Núcleo
\mathcal{N}	Modelo de regressão
\mathbf{H}	Hessiana
\mathbf{S}	Amostra
\mathbf{C}	Covariância
\mathbf{E}	Matriz dos auto-vetores de \mathbf{C}

Gregos

Escalares:

α	Tamanho do passo da direção de busca; Correção aditiva
β	Correção multiplicativa
ρ	Termo de aceitação
Δ	Tamanho da região de confiança

σ_E Desvio padrão

Vetores:

β Coeficientes de regressão incógnitos

ξ Variáveis aleatórias

λ Multiplicadores de Lagrange; autovalor de C

v Autovetor de C

Matrizes:

Λ Matriz diagonal de autovalores de C

Matemáticos

∇ Operador Nabla

\in Pertencente

∂ Derivada parcial

Σ Somatório

Π Produtório

\mathbb{R} Conjunto ou espaço dos números reais

$=, \neq, \approx$ Igual; diferente; aproximadamente igual

$>, \geq, \gg$ Maior que; maior ou igual à; muito maior que

$<, \leq$ Menor que; menor ou igual à

\int Integral

I. Sumário

LISTA DE FIGURAS.....	XIII
LISTA DE TABELAS.....	XIV
1 INTRODUÇÃO.....	15
2 FUNDAMENTAÇÃO TEÓRICA.....	19
2.1 OTIMIZAÇÃO.....	19
2.1.1 Introdução.....	19
2.1.2 Programação Quadrática Sequencial - SQP.....	22
2.2 SIMULAÇÃO NUMÉRICA DE RESERVATÓRIOS.....	25
3 APROXIMAÇÕES.....	28
3.1 INTRODUÇÃO.....	28
3.2 FUNÇÕES SUBSTITUTAS BASEADAS NO MODELO FUNCIONAL.....	30
3.2.1 Método de Superfície de Resposta.....	30
3.2.2 Técnicas de Amostragem.....	32
3.2.3 Modelo de Regressão Polinomial.....	37
3.2.4 Otimização por Aproximação Sequencial (SAO).....	39
4 AJUSTE DE HISTÓRICO.....	47
4.1 SELEÇÃO DAS VARIÁVEIS DE PROJETO.....	48
4.2 PROBLEMA INVERSO.....	49
4.3 AJUSTE MANUAL E ASSISTIDO.....	50
4.4 SELEÇÃO DOS ALGORITMOS DE OTIMIZAÇÃO.....	52
4.5 FORMULAÇÃO DO PROBLEMA.....	54
4.5.1 Função-Objetivo.....	54
4.5.2 Variáveis de Projeto.....	55
4.5.3 Restrições de Limite.....	55
5 IMPLEMENTAÇÃO COMPUTACIONAL.....	56
5.1 FERRAMENTAS.....	56
5.1.1 IMEX.....	56
5.1.2 DAKOTA.....	58
5.1.2.1 Estratégia de Otimização no DAKOTA.....	60
5.1.2.2 Implementação da Estratégia de Otimização Aproximada Sequencial (SAO) no DAKOTA.....	62
5.1.3 OCTAVE.....	64
5.2 METODOLOGIA.....	64
5.3 SCRIPTS - PROGRAMAS ADICIONAIS.....	68
6 APLICAÇÕES.....	71
6.1 DESCRIÇÃO DO CENÁRIO.....	71
6.2 CASOS PROPOSTOS PARA ESTUDO.....	72
6.2.1 Ajuste A.....	73
6.2.1.1 Ajuste A - Caso 1: Uma variável de projeto; Contraste de permeabilidade 1:3.....	78
6.2.1.2 Ajuste A - Caso 2: Três variáveis de projeto.....	82
6.2.1.3 Ajuste A - Caso 3: Uma variável de projeto; Permeabilidade constante no reservatório.....	86
6.2.2 Ajuste B.....	90
6.2.2.1 Ajuste B - Caso 1: Uma variável; Permeabilidade constante no reservatório.....	93

6.2.2.2 Ajuste B - Caso 2: Uma variável de projeto	95
6.2.2.3 Ajuste B - Caso 3: Duas variáveis de projeto	98
6.3 PREVISÃO FUTURA.....	100
7 CONCLUSÃO	104
7.1 CONSIDERAÇÕES FINAIS	104
7.2 SUGESTÕES PARA TRABALHOS FUTUROS	106
8 REFERÊNCIAS	108

LISTA DE FIGURAS

<i>Figura 1 - Método Quase-Monte Carlo – QMC</i>	33
<i>Figura 2 - Método Latin Centroidal Voronoi Tessellation – LCVT</i>	34
<i>Figura 3 - Método Latin Hypercube Sampling – LHS</i>	34
<i>Figura 4 - Divisão em cinco intervalos do domínio de duas variáveis aleatórias (a) distribuição normal (b) distribuição uniforme (Penna, 2009)</i>	35
<i>Figura 5 - Valores sorteados para cada variável (Penna, 2009)</i>	36
<i>Figura 6 - Representação bi-dimensional de uma possível amostragem por LHS (Penna, 2009)</i>	36
<i>Figura 7 - Fluxograma da SAO</i>	40
<i>Figura 8 - Evolução do esquema SAO no problema de otimização [11]</i>	44
<i>Figura 9 - Etapas do Ajuste de Histórico (Leitão, 1997)</i>	53
<i>Figura 10 - Arquivos de entrada e saída do IMEX</i>	57
<i>Figura 11 - Interface entre o DAKOTA e o Simulador (Dakota Version 5.0 User's Manual)</i>	60
<i>Figura 12 - Esquema do ajuste de histórico assistido implementado neste trabalho</i>	68
<i>Figura 13 - Fluxograma dos Scripts</i>	69
<i>Figura 14 - Regiões de Permeabilidade Horizontal</i>	74
<i>Figura 15 - Curva de Produção Acumulada de Óleo Observada – Caso C1</i>	76
<i>Figura 16 - Curva de Produção Acumulada de Óleo Observada – Caso C2</i>	76
<i>Figura 17 - Curva de Produção Acumulada de Óleo Observada – Caso C3</i>	77
<i>Figura 18 - Curva de Produção Acumulada de Óleo Observada – Caso C4</i>	77
<i>Figura 19 - Ajuste da Produção de Óleo – Caso C1</i>	80
<i>Figura 20 - Ajuste da Produção de Óleo – Caso C2</i>	80
<i>Figura 21 - Ajuste da Produção de Óleo – Caso C3</i>	81
<i>Figura 22 - Ajuste da Produção de Óleo – Caso C4</i>	81
<i>Figura 23 - Ajuste da Produção de Óleo – Caso C1</i>	84
<i>Figura 24 - Ajuste da Produção de Óleo – Caso C2</i>	85
<i>Figura 25 - Ajuste da Produção de Óleo – Caso C3</i>	85
<i>Figura 26 - Ajuste da Produção de Óleo – Caso C4</i>	86
<i>Figura 27 - Ajuste da Produção de Óleo – Caso C1</i>	88
<i>Figura 28 - Ajuste da Produção de Óleo – Caso C2</i>	89
<i>Figura 29 - Ajuste da Produção de Óleo – Caso C3</i>	89
<i>Figura 30 - Ajuste da Produção de Óleo – Caso C4</i>	90
<i>Figura 31 - Campo base</i>	93
<i>Figura 32 - Campo de permeabilidade constante inicial</i>	94
<i>Figura 33 - Ajuste da Produção de Óleo</i>	95
<i>Figura 34 - Ajuste da Produção de Óleo</i>	97
<i>Figura 35 - Campo com ajuste de histórico</i>	98
<i>Figura 36 - Ajuste da Produção de Óleo</i>	99
<i>Figura 37 - Campo com ajuste de histórico</i>	100
<i>Figura 38 - Previsão futura - Ajuste A – Caso 2 (C1)</i>	101
<i>Figura 39 - Previsão futura - Ajuste A – Caso 2 (C2)</i>	102
<i>Figura 40 – Previsão futura - Ajuste B – Caso 3</i>	103

LISTA DE TABELAS

<i>Tabela 1 – Etapas do algoritmo SQP (Silva, 2009).....</i>	<i>25</i>
<i>Tabela 2 – Procedimentos da estratégia SAO (Silva, 2009).....</i>	<i>43</i>
<i>Tabela 3 - Termo de aceitação no esquema da região de confiança [11]</i>	<i>46</i>
<i>Tabela 4 – Controles independentes do método NPSOL.....</i>	<i>61</i>
<i>Tabela 5 – Controles dependentes do método NPSOL.....</i>	<i>62</i>
<i>Tabela 6 – Controles SAO no DAKOTA.</i>	<i>62</i>
<i>Tabela 7 – Controle da Região de Confiança no DAKOTA.</i>	<i>63</i>
<i>Tabela 8 - Descrição e parâmetros de entrada do script de pré-processamento.</i>	<i>70</i>
<i>Tabela 9 – Descrição e parâmetros de entrada do script de pós-processamento.</i>	<i>70</i>
<i>Tabela 10 – Restrição no poço.....</i>	<i>72</i>
<i>Tabela 11 - Resumo das características do modelo base.</i>	<i>74</i>
<i>Tabela 12 - Resultado da Otimização- C1.....</i>	<i>79</i>
<i>Tabela 13 - Resultado da Otimização- C2.....</i>	<i>79</i>
<i>Tabela 14 - Resultado da Otimização- C3.....</i>	<i>79</i>
<i>Tabela 15 - Resultado da Otimização- C4.....</i>	<i>79</i>
<i>Tabela 16 - Resultado da Otimização – C1.</i>	<i>83</i>
<i>Tabela 17 – Resultado da Otimização – C2.</i>	<i>83</i>
<i>Tabela 18 – Resultado da Otimização – C3.</i>	<i>83</i>
<i>Tabela 19 – Resultado da Otimização – C4.</i>	<i>83</i>
<i>Tabela 20 - Resultado da Otimização- C1.....</i>	<i>87</i>
<i>Tabela 21 - Resultado da Otimização- C2.....</i>	<i>87</i>
<i>Tabela 22 - Resultado da Otimização- C3.....</i>	<i>87</i>
<i>Tabela 23 - Resultado da Otimização- C4.....</i>	<i>87</i>
<i>Tabela 24 - Resultado da Otimização.....</i>	<i>94</i>
<i>Tabela 25 - Resultado da Otimização.....</i>	<i>96</i>
<i>Tabela 26 - Resultado da Otimização.....</i>	<i>99</i>

1 Introdução

Nos últimos anos, o crescente desenvolvimento da área de simulação computacional tem transformado esse recurso em uma ferramenta de uso rotineiro. Esta ferramenta pode fornecer informações que irão auxiliar nas decisões de gerenciamento de reservatório durante todo seu ciclo de vida.

A função da simulação de reservatórios é auxiliar os engenheiros no entendimento do comportamento de um reservatório e, conseqüentemente, prever as taxas de produção em função do tempo. A previsão da produção auxilia os gerentes a decidir sobre a viabilidade do projeto, quando expressa em termos de rendimentos e comparada com custos e investimentos.

A complexidade dos reservatórios de petróleo e a conseqüente dificuldade em modelar o problema com precisão, através de modelos analíticos, fazem com que seja necessária a utilização da simulação numérica, a qual permite a obtenção de uma previsão do comportamento do reservatório com base em um modelo numérico, previamente construído a partir de diversos parâmetros gerados durante a caracterização do campo de petróleo.

No entanto, construir um modelo de simulação que incorpore adequadamente a caracterização geológica do reservatório (permeabilidades absolutas e relativas, porosidades, compressibilidades, etc.) e reproduza satisfatoriamente as informações dinâmicas disponíveis (vazões, pressões, saturações) continua sendo uma tarefa árdua. Trata-se de um processo demorado, cuja execução é dividida em quatro etapas principais: i) caracterização do campo; ii) definição e construção do modelo de simulação; iii) ajuste de histórico de produção; e iv) previsão de produção.

Inicialmente, a caracterização do reservatório possui todas as informações disponíveis que são utilizadas para conceber modelos geológicos e de fluxo que representem adequadamente o campo em estudo. Com estes dados, geram-se

informações sobre a geometria do sistema, propriedades dos fluidos e da rocha, assim como distribuições iniciais de pressões e saturações.

O passo seguinte é a definição e construção de um modelo de simulação que contenha adequadamente as características do campo. Nesta etapa são definidos parâmetros como número de fases (monofásico, bifásico ou trifásico), geometria (retangular, radial, etc.), número de blocos e de camadas e tipo de modelo (Black-Oil, composicional, etc.).

Após a confecção do modelo, pode-se considerá-lo como eficiente se este for capaz de desempenhar adequadamente os objetivos do estudo com uma menor quantidade possível de recursos. Geralmente, isto pode ser obtido, desconsiderando soluções demasiadamente complexas e que requeiram informações não disponíveis.

Na etapa de ajuste de histórico são realizadas mudanças no modelo de simulação de modo que os resultados obtidos por meio da simulação se tornem bem próximos dos dados reais de produção do campo. O modelo criado é utilizado para realizar previsões futuras do reservatório, provendo subsídios para uma exploração mais confiável. A qualidade do comportamento da previsão futura será tanto melhor quanto maior for o conhecimento do reservatório, obtido através de sua melhor caracterização e representação.

A motivação para este trabalho surgiu da necessidade de desenvolver uma metodologia para automatizar o processo de ajuste de histórico de produção por um ajuste assistido, em simulação numérica de reservatório de petróleo, através da minimização matemática de uma função-objetivo utilizando-se de um método de otimização baseado na estratégia de Otimização Aproximada Sequencial (SAO).

A estratégia SAO decompõe o problema original em vários subproblemas de otimização, onde cada subproblema é confinado a uma pequena região do espaço de projeto [15] [17]. O esquema iterativo de atualização da região de confi-

ança proposto por Alexandrov e Dennis foi adotado para obtenção do novo espaço de projeto em cada iteração [4].

Para solução do problema de ajuste de histórico foram empregados o framework DAKOTA, o simulador IMEX e a linguagem OCTAVE, que trabalharão integrados com programas adicionais, com o objetivo de complementar a estrutura do sistema computacional através de rotinas necessárias à solução do problema.

Para cálculo da função-objetivo foram utilizadas as informações históricas da produção do reservatório, aqui denominadas “produção observada”, juntamente com um histórico de produção obtido através da simulação computacional, aqui denominado “produção calculada”. Os valores da produção calculada serão gerados durante a simulação e capturados em um programa específico. Durante o ciclo SAO, o otimizador procura encontrar por meio de suas técnicas a solução ótima do problema.

A dissertação está dividida em sete capítulos: no primeiro capítulo, é apresentada uma breve introdução sobre o tema e uma descrição sumária da solução proposta. No segundo capítulo, para um melhor entendimento sobre o assunto, é exposta uma breve revisão sobre a otimização, o algoritmo de otimização SQP (Sequential Quadratic Programming) e a simulação numérica de reservatório.

As aproximações são descritas no terceiro capítulo, onde serão definidas as metodologias para construção do modelo substituto (metamodelo). Foram consideradas as funções substitutas da forma funcional baseadas no ajuste de pontos (Data Fitting), especificamente usando o método dos mínimos quadrados (MMQ) aliado à estratégia da superfície de resposta; assim como as técnicas de amostragens (Design of Experiments - DOE) e o modelo de regressão polinomial. Será também apresentada neste capítulo a definição da estratégia de Otimização Aproximada Sequencial (SAO), juntamente com a implementação do esquema da região de confiança, necessária para a atualização do espaço de projeto de cada sub-problema do SAO.

No quarto capítulo é apresentado o conceito de ajuste de histórico e suas principais características, bem como a seleção dos algoritmos de otimização. Também será abordada a formulação do problema, definindo a função-objetivo, as variáveis de projeto e as restrições de limite.

O quinto capítulo trata da implementação computacional, apresentando o conceito das ferramentas utilizadas na solução do problema de ajuste de histórico (DAKOTA, IMEX e OCTAVE), bem como a metodologia proposta neste trabalho e os programas adicionais integrados ao DAKOTA e ao IMEX.

O sexto capítulo contém a descrição física e numérica dos modelos de reservatório utilizados nas aplicações; a apresentação dos dois ajustes propostos para estudo, representados por um campo de permeabilidade com três regiões distintas e um campo de permeabilidade estocástico; e a avaliação do comportamento da previsão futura da produção.

No sétimo capítulo serão resumidas as abordagens feitas nesta dissertação. As conclusões obtidas através dos diversos resultados serão também descritas e discutidas, assim como sugestões que poderão ser estudadas em trabalhos futuros.

A bibliografia consultada é apresentada no final desta dissertação.

2 Fundamentação Teórica

Neste capítulo serão revistos os conceitos básicos associados a alguns temas importantes que serão abordados no decorrer da dissertação, por exemplo, otimização e simulação computacional.

2.1 Otimização

2.1.1 Introdução

Em um projeto de engenharia está envolvido, normalmente, um grande número de variáveis. Cabe ao projetista encontrar uma combinação para estas variáveis que resulte em um projeto o mais eficiente e idealmente o mais econômico possível. Normalmente, a determinação desta melhor configuração para os parâmetros de projeto depende fundamentalmente da experiência e da intuição do projetista. Técnicas de otimização podem ser utilizadas para auxiliar o projetista na determinação do projeto ótimo. O objetivo da otimização é encontrar, de acordo com o critério escolhido, a melhor solução entre as diversas combinações possíveis para as variáveis de projeto, mantendo a viabilidade do projeto, que está associada a restrições que devem ser satisfeitas [3].

Uma vez construído um modelo matemático do problema, a formulação do problema de otimização pode ser descrita matematicamente pela seguinte expressão:

$$\begin{aligned}
\text{Minimize} \quad & f(\mathbf{x}) \\
\text{Sujeito à:} \quad & \mathbf{g}_j(\mathbf{x}) \leq 0 \quad j = 1 \dots p \\
& \mathbf{h}_k(\mathbf{x}) = 0 \quad k = 1 \dots q \\
& \mathbf{x}_i^l \leq \mathbf{x}_i \leq \mathbf{x}_i^u \quad i = 1 \dots n
\end{aligned} \tag{2.1}$$

onde \mathbf{x} , $f(\mathbf{x})$, $\mathbf{g}(\mathbf{x})$, $\mathbf{h}(\mathbf{x})$, \mathbf{x}^L e \mathbf{x}^U representam, respectivamente, o vetor das variáveis de projeto, a função-objetivo, os vetores das restrições de desigualdade e igualdade, os limites inferiores e superiores dos vetores das variáveis de projeto. Além disto, p , q e n representam, respectivamente, o número das restrições de desigualdade e igualdade e das variáveis de projeto, e j , k e i os respectivos índices das coordenadas dos vetores.

O vetor \mathbf{x} representa o conjunto das variáveis de projeto cujos valores procuramos especificar através do processo de otimização. De maneira genérica, se o vetor \mathbf{x} possui n variáveis reais, dizemos que $\mathbf{x} \in R^n$.

A próxima entidade presente na Equação (2.1) é a chamada função-objetivo $f(\cdot)$, que representa o índice de desempenho do sistema, cujo valor, por convenção, queremos minimizar para atingirmos o desempenho ótimo.

Para simplificar a tarefa de elaborar a teoria matemática de otimização, iremos manter a convenção de sempre formular um problema de otimização como um problema de minimização. Nos casos em que desejamos fazer uma maximização, devido ao significado do índice de desempenho escolhido, basta minimizarmos a função que se deseja maximizar multiplicada por -1.

A otimização procura encontrar por meio de suas técnicas a melhor solução, no qual o vetor ótimo \mathbf{x}^* é igual ao argumento da função $f(\cdot)$ que faz com que essa função atinja seu mínimo valor.

Para finalizar a formulação contida na Equação (2.1), ainda falta entender o significado da igualdade e da desigualdade as quais está sujeito o resultado da

otimização. Essas são as chamadas restrições do problema, que são descritas pelas expressões:

$$\mathbf{g}(\mathbf{x}) \leq 0$$

$$\mathbf{h}(\mathbf{x}) = 0$$

As restrições do problema significam o conjunto de requisitos que o resultado do projeto deve atender para ser admissível enquanto solução.

Para concluir este tópico, definimos a seguinte nomenclatura, relacionada às restrições:

- Região Viável: Conjunto de pontos do espaço R^n que satisfaçam, simultaneamente, a todas as restrições (tanto de desigualdade quanto de igualdade).
- Região Inviável: Conjunto dos pontos do espaço R^n , que deixam de satisfazer (ou seja, violam) pelo menos uma das restrições do problema.
- Ponto Viável: Ponto pertencente à região viável.
- Ponto Inviável: Ponto pertencente à região inviável.
- Restrição Violada: Cada uma das componentes do vetor $\mathbf{g}(\mathbf{x})$ que apresentar valor positivo, ou cada uma das componentes do vetor $\mathbf{h}(\mathbf{x})$ que apresentar valor não-nulo será chamada de restrição violada no ponto \mathbf{x} .

O processo de otimização é realizado através da implementação de algoritmos, cujo objetivo é determinar as soluções do problema (Equação (2.1)). Esses algoritmos irão requerer a avaliação da função-objetivo e de restrição, devendo, entretanto fazer estas avaliações um menor número de vezes que for possível.

A função-objetivo do nosso problema será definida como a norma da diferença entre um histórico de produção observado e um histórico de produção obtido através da simulação computacional e como candidatas as variáveis de projeto, teremos as permeabilidades absoluta, que devem ser escolhidas de forma a encontrar a melhor solução entre as diversas configurações possíveis.

2.1.2 Programação Quadrática Sequencial - SQP

Nesta dissertação o problema apresentado na Equação (2.1) será solucionado utilizando o algoritmo de programação quadrática sequencial (SQP) aplicada a problema de otimização não linear.

A programação quadrática sequencial pode ser considerada como o resultado da aplicação do método de Newton à minimização de uma aproximação quadrática da função Lagrangeana do problema [29].

O algoritmo SQP usado neste trabalho utiliza um método baseado num esquema de procura unidimensional e envolve dois processos iterativos - um interno e outro externo. No processo iterativo interno resolve-se um subproblema quadrático para determinar a direção de busca. Uma vez encontrada, o processo iterativo externo calcula uma nova aproximação da Hessiana da função de Lagrange, que é atualizada com a aproximação Quasi-Newton BFGS (Broyden-Fletcher-Goldfarb-Shanno) [32].

A seqüência de aproximações geradas pelo processo iterativo externo converge para um ponto que verifica as condições de primeira ordem ou KKT (Karush-Kunn-Tucker) :

1. Viabilidade:

$$\begin{aligned} g_j(\mathbf{x}^*) &\leq 0, & j = 1, \dots, p \\ h_k(\mathbf{x}^*) &= 0, & k = 1, \dots, q \end{aligned} \tag{2.2}$$

2. Estacionaridade:

$$\nabla_{\mathbf{x}} L(\mathbf{x}^*, \boldsymbol{\lambda}^*) = \nabla f(\mathbf{x}^*) + \sum_{j=1}^p \lambda_j^* \nabla g_j(\mathbf{x}^*) + \sum_{k=1}^q \lambda_k^* \nabla h_k(\mathbf{x}^*) = 0 \tag{2.3}$$

onde $L(\mathbf{x}^*, \boldsymbol{\lambda}^*)$ é a função Lagrangeana dada pela expressão a seguir:

$$L(\mathbf{x}^*, \boldsymbol{\lambda}^*) = f(\mathbf{x}^*) + \sum_{j=1}^p \lambda_j^* g_j(\mathbf{x}^*) + \sum_{k=1}^q \lambda_k^* h_k(\mathbf{x}^*) \quad (2.4)$$

onde $\boldsymbol{\lambda}^*$ é o vetor com os multiplicadores de Lagrange associados às restrições de igualdade e desigualdade no ponto \mathbf{x}^* .

3. Complementaridade:

$$\lambda_j g_j(\mathbf{x}^*) = 0, \quad j = 1 \dots p \quad (2.5)$$

4. Positividade:

$$\lambda_j \geq 0, \quad j = 1, \dots, p \quad (2.6)$$

Para determinadas classes de problemas de programação matemática as condições KKT são suficientes para a determinação de solução ótima global.

No algoritmo de otimização é fornecido um ponto inicial \mathbf{x}_0 e o projeto é então atualizado modificando \mathbf{x} através da equação (2.7).

$$\mathbf{x}_t = \mathbf{x}_{t-1} + \alpha \mathbf{d}_t \quad (2.7)$$

onde

\mathbf{x}_t é o ponto atual na iteração t

t é o índice que indica o número da iteração

$\mathbf{d} = [d_1, d_2, \dots, d_n]^T$ é o vetor que indica a direção de busca e a direção viável para qual o valor de $f(\mathbf{x})$ decresce

α é o tamanho do passo na direção de \mathbf{d}

Uma sequência de subproblemas quadráticos é resolvida no algoritmo SQP e a função-objetivo é uma aproximação quadrática da Lagrangeana.

O algoritmo SQP utiliza a informação de segunda ordem da função a otimizar, sendo assim a função $f(\mathbf{x})$ é expandida até a segunda ordem, ou seja, a expansão de Taylor em $\bar{\mathbf{x}}$, de acordo com:

$$f(\mathbf{x}) = f(\bar{\mathbf{x}}) + \mathbf{d}^T \nabla f(\bar{\mathbf{x}}) + \frac{1}{2} \mathbf{d}^T \nabla^2 L(\bar{\mathbf{x}}) \mathbf{d} \quad (2.8)$$

onde $\mathbf{d} = \mathbf{x} - \bar{\mathbf{x}}$ é a direção de busca e $\nabla f(\bar{\mathbf{x}})$ é o vetor gradiente de f em $\bar{\mathbf{x}}$, de quem os elementos são definidos por:

$$\nabla f_i = \frac{\partial f}{\partial x_i} \quad (2.9)$$

e $\nabla^2 L(\bar{\mathbf{x}})$ é a Hessiana da função de Lagrangeana $L(\mathbf{x}^*, \boldsymbol{\lambda}^*)$ (Equação (2.4)) que é atualizada a cada iteração:

$$\nabla^2 L(\mathbf{x}^*, \boldsymbol{\lambda}^*) = \nabla^2 f(\mathbf{x}^*) + \sum_{j=1}^p \lambda_j^* \nabla^2 g_j(\mathbf{x}^*) + \sum_{k=1}^q \lambda_k^* \nabla^2 h_k(\mathbf{x}^*) \quad (2.10)$$

Na Tabela 1 são apresentadas as principais etapas envolvidas no algoritmo SQP convencional [38].

Tabela 1 – Etapas do algoritmo SQP (Silva, 2009).

Etapa	Descrição
SQP 1.	Estabelecer uma solução inicial \mathbf{x}_0 ;
SQP 2.	Configurar uma aproximação inicial para a matriz Hessiana dos termos quadráticos da função-objetivo;
SQP 3.	Resolver o subproblema para encontrar a direção de busca \mathbf{d} ;
SQP 4.	Realizar uma busca linear para determinar o tamanho do passo α na direção \mathbf{d} ;
SQP 5.	Atualizar a solução, remetendo-a para a posição indicada;
SQP 6.	Verificar a convergência do algoritmo SQP:
6.1.	Se o mínimo local for encontrado: o processo termina.
6.2.	Caso contrário: atualiza-se a matriz Hessiana via o esquema BFGS e volta para o passo SQP 3.

2.2 Simulação Numérica de Reservatórios

A importância da indústria do petróleo vem crescendo desde a segunda metade do século XIX, quando o primeiro poço entrou em produção, em Titusville, Pensilvânia, sob o comando do coronel Drake. Desde então, verificou-se uma acirrada corrida em busca da descoberta de novos campos. A indústria do petróleo tem um papel importante no cenário mundial. A participação do óleo e gás natural na matriz energética mundial indica uma forte dependência desta forma de energia não renovável [43]. Considerando que somente uma parte do petróleo existente no mundo pode ser produzida economicamente, se faz necessária uma busca contínua dos meios para aumentar sua recuperação. Para tanto, é importante um conhecimento cada vez melhor dos mecanismos de produção que afetam a recuperação de petróleo com impacto nas previsões de produção. Estas, em última análise, afetam diretamente a economicidade dos projetos, viabilizando projetos de desenvolvimento de campos petrolíferos.

A engenharia de reservatórios é responsável pelo estudo do escoamento dos fluidos dentro do meio poroso, cálculo das reservas, definição dos métodos de recuperação secundária e terciária, esquemas de desenvolvimento do campo, entre outros.

A simulação numérica é uma das mais poderosas ferramentas para guiar decisões de gerenciamento de reservatório em todos os estágios de vida de um reservatório de petróleo. Um simulador numérico contendo informações corretas pode simular o comportamento de um reservatório, predizendo sua produção sob condições de operação corrente, ou a reação dele mediante alteração dessas condições.

A função da simulação do reservatório é auxiliar os engenheiros a entender o comportamento de um reservatório e conseqüentemente predizer as taxas de produção como uma função do tempo. A previsão da produção futura, quando expressa em termos de rendimentos e comparada com custos e investimentos, auxilia os gerentes a decidirem sobre a viabilidade do projeto.

Os princípios que fundamentam a simulação numérica são bastante simples. Em primeiro lugar, princípios fundamentais como a conservação de massa e energia, leis constitutivas e equações de estado são usadas para determinar os sistemas de equações diferenciais parciais que regem o escoamento do fluido em meios porosos. Com o emprego de uma técnica de discretização, como o método das diferenças finitas ou de volumes finitos, por exemplo, o sistema de equações diferenciais parciais é transformado em um sistema de equações algébricas que pode ser resolvido diretamente em um computador digital.

No processo de discretização, o volume do reservatório é tratado com um conjunto numerado de blocos e o período de produção do reservatório é dividido em um numero finito de etapas de tempo.

Existem vários simuladores que possuem uma variedade de características e eles em geral se encaixam em duas categorias principais. Na primeira categoria estão os simuladores “black-oil”, para reservatórios contendo água, gás e

óleo. Na segunda categoria estão os simuladores térmicos e composicionais, para reservatórios que requerem descrição mais detalhada da composição do fluido.

Nesta dissertação será usado o simulador IMEX (IMplicit EXplicit black oil simulator), que é um programa de simulação de reservatórios bastante conhecido no mundo e, em particular, muito usado pela Petrobras. Este software desenvolvido pela CMG (Computer Modelling Group Ltd.) é um simulador trifásico que utiliza o modelo “black-oil”, e suporta malhas cartesianas, malhas cilíndricas, malhas regulares com profundidade e espessura variáveis, e malhas de vértices (corner-point), com configurações em duas ou três dimensões [08].

3 Aproximações

3.1 Introdução

Dentro da atividade de Engenharia de Petróleo, onde há uma busca constante por projetos otimizados e eficientes na produção e desenvolvimento de reservas de petróleo, modelos aproximados (metamodelos) estão sendo bem utilizados.

O uso de ferramentas de otimização com simulações em projetos de engenharia de petróleo, às vezes, torna-se inviável, devido a soluções que tomam muito tempo para serem encontradas por resultarem em simulação complexa e/ou demoradas. Esse elevado custo computacional é devido principalmente a grande quantidade de simulações numéricas realizadas durante o processo, uma vez que este procedimento requer sucessivas avaliações das funções e suas derivadas.

Neste capítulo é apresentado uma alternativa para este tipo de problema de otimização. Isto é feito utilizando-se funções substitutas - que são menos custosas de serem realizadas, no qual amenizam o esforço computacional gerado durante o processo de otimização existente para esta classe de aplicação. Desta maneira, torna-se viável a utilização de um algoritmo de otimização, sem a necessidade de executar o simulador numérico de uma forma intensiva.

As funções substitutas têm sido utilizadas objetivando uma resposta computacional rápida, e também para se obter um comportamento mais suave e/ou simplificada das funções caras computacionalmente (alta fidelidade), isto é, livres de ruído numérico, que é um problema típico de funções avaliadas a partir de um procedimento numérico. O fator essencial na aproximação é substituir as funções de alta fidelidade (custosas) por funções mais simples de serem calculadas (funções substitutas) e usar essas funções durante o processo de otimização.

As aproximações podem ser classificadas, segundo o seu intervalo de aplicabilidade no espaço de projeto. Conseqüentemente, três grupos distintos podem ser definidos [5]:

1. Aproximações locais: São válidas apenas em uma vizinhança próxima de onde as funções foram criadas. Durante o processo da otimização os resultados da função real são comparados a cada iteração com os da função aproximada, resultando em uma consistência entre os dois modelos. Este tipo é mais apropriado quando se faz o uso do processo iterativo. Esta estratégia de otimização é comumente referida na literatura como Sequential Approximation Optimization (SAO) [15], aqui traduzida como Otimização Sequencial Aproximada;
2. Aproximações globais: Ocorre quando é necessário obtermos uma idéia geral da função investigada em todo o espaço de projeto. Tais aproximações serão criadas construindo uma superfície de resposta global utilizando modelo por ajuste de pontos (Data Fitting);
3. Aproximações de médio-alcance: Tenta dar um aspecto global para as aproximações do tipo locais, ou seja, é a combinação entre ambos os tipos.

As aproximações podem assumir as seguintes formas [28]:

1. Funcional: a aproximação da função real é obtida pela interpolação de valores conhecidos da função-objetivo;
2. Física: os modelos são criados a partir de modelos físicos simplificados;
3. Híbrido: modelos resultantes da combinação entre os modelos físico e funcional.

No presente trabalho apenas as funções substitutas baseadas no modelo funcional serão utilizadas e esta técnica será discutida com mais detalhes a seguir.

3.2 Funções Substitutas baseadas no Modelo Funcional

A forma funcional pode ser baseada em séries numéricas (baseadas em expansão por série de Taylor) ou superfícies de respostas obtidas através do ajuste de pontos.

Apenas as funções substitutas da forma funcional baseadas no ajuste de pontos (Data Fitting), especificamente usando o método dos mínimos quadrados (MMQ) aliado à estratégia da superfície de resposta serão abordado neste trabalho. As técnicas de ajuste de pontos são geralmente selecionadas quando um modelo físico simplificado não é possível de ser obtido. A forma funcional aqui estudada é em termos de funções aproximadas que podem ser escritas com uma expressão matemática dependente de parâmetros calculados por técnicas de ajuste de superfícies.

3.2.1 Método de Superfície de Resposta

O método de Superfície de Resposta (SR) foi desenvolvido por Box e Wilson em 1951 [6]. Este método descreve a função resposta em termos de uma superfície, buscando ajustar um polinômio à função-objetivo, que é obtido a partir do modelo de regressão.

Observa-se que tal modelo é preciso apenas quando uma pequena região do espaço do projeto é investigada. Entretanto, esta técnica é largamente utilizada nas mais diversas áreas, devido à fácil aplicação e simplicidade na obtenção do modelo aproximado [38].

A otimização gerada a partir da SR possui uma grande vantagem em comparação com os demais métodos por não necessitar do cálculo dos gradientes das funções do modelo de alta precisão (custosas), como também possibilita a

suavização dos resultados provenientes das análises e/ou experimentos ao se utilizar regressões de baixa ordem (lineares, quadráticas, ou cúbicas).

O método dos mínimos quadrados (MMQ) é um dos métodos de ajuste de pontos bastante empregado. Usando este método (MMQ), expressões analíticas são formuladas e usadas em substituição às funções do modelo de alta precisão.

Para construir uma forma analítica aproximada é necessário gerar uma amostra representativa do espaço de projeto através de técnicas de amostragem (Design of Experiments - DOE) e um modelo de regressão, que serão apresentados com mais detalhes nas próximas sessões.

Para um vetor de entrada \mathbf{x} a função aproximada considerando a estratégia da superfície de resposta terá o modelo de regressão descrito abaixo [38]:

$$\hat{f}_{SR}(\mathbf{x}) = \sum_{j=1}^k \beta_j N_j = \mathbf{N}(\mathbf{x}) \boldsymbol{\beta}^T \quad (3.1)$$

onde $\mathbf{N}(\mathbf{x})$ representa um vetor do modelo de regressão a ser escolhido:

$$\mathbf{N}(\mathbf{x}) = [N_1(\mathbf{x}) \quad \cdots \quad N_k(\mathbf{x})] \quad (3.2)$$

$\boldsymbol{\beta}$ é o vetor dos coeficientes do modelo de regressão a ser determinado, que é formulado na equação abaixo:

$$\mathbf{f}_S \approx \mathcal{N} \boldsymbol{\beta}^T \quad (3.3)$$

onde:

$$\boldsymbol{\beta}^T = [\beta_0 \quad \cdots \quad \beta_{k-1}] \quad (3.4)$$

k é o número de elementos em $\boldsymbol{\beta}$ e $\mathbf{N}(\mathbf{x})$

\mathbf{f}_S é um vetor de tamanho m que contém os resultados da função real avaliados nos pontos de uma amostra $\mathbf{S} = [\mathbf{x}_1 \quad \cdots \quad \mathbf{x}_m]$:

$$\mathbf{f}_S = f(\mathbf{S}) = [f(\mathbf{x}_1) \quad \cdots \quad f(\mathbf{x}_m)]$$

m é a dimensão da amostra

Considerando a amostra \mathbf{S} , os termos da forma polinomial de regressão constroem uma matriz \mathcal{N} formada por m linhas e k colunas, dada por [38]:

$$\mathcal{N} = \begin{bmatrix} N_1(\mathbf{x}_1) & \cdots & N_k(\mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ N_1(\mathbf{x}_m) & \cdots & N_k(\mathbf{x}_m) \end{bmatrix} \quad (3.5)$$

Os termos do vetor β são a solução do problema de regressão, definido pela Equação (3.3), o qual é resolvido usando o método dos mínimos quadrados definido abaixo [38],

$$\beta = (\mathcal{N}^T \mathcal{N})^{-1} \mathcal{N}^T \mathbf{f}_s \quad (3.6)$$

onde para que o termo $\mathcal{N}^T \mathcal{N}$ exista, é necessário que as linhas da matriz \mathcal{N} sejam linearmente independentes. Sendo assim, ao substituirmos o vetor β na Equação (3.1), podemos calcular o valor aproximado da função \hat{f}_{SR} em qualquer ponto do espaço de projeto.

3.2.2 Técnicas de Amostragem

O primeiro passo para construção de metamodelos por ajuste de pontos é gerar um conjunto de pontos (amostra) que sejam únicos e limitados pelo limite inferior e superior do espaço de projeto. Estas técnicas são conhecidas na literatura como Design of Experiments (DOE) [18][14], aqui traduzida como técnica de amostragem.

A técnica de amostragem é uma técnica estatística para planejar, executar e analisar experimentos, ou seja, para definir quais dados, em que quantidade e em que condições devem ser coletados durante um determinado experimento, buscando, basicamente, satisfazer dois grandes objetivos: a maior precisão estatística possível na resposta e o menor custo.

Como a localização dos pontos da amostra pode influenciar o modelo criado, pois em cada ponto da amostra a função real é avaliada, para se obter um

bom modelo substituto a seleção da amostra é uma importante etapa, especialmente quando o tempo da análise para um único experimento é longo. Portanto deve-se obter uma amostra “representativa” do espaço de projeto com um menor número possível de amostras, que assegure a precisão do modelo aproximado com relação ao modelo real. Tal amostra pode ser obtida a partir de diversos métodos disponíveis, dos quais podemos citar: Hipercubo Latino (Latin Hypercube Sampling (LHS)), Vetor Ortogonal (Orthogonal Array (OA)), Ladrilhamento de Voronoy Latinizado (Latinized Centroidal Voronoi Tessellation (LCVT)), Quasi Monte Carlo (QMC), Amostragem Randômica Simples (Simple Random Sampling (SRS)) [11]

As figuras abaixo demonstram a distribuição de três diferentes amostras contendo 20 pares ordenados (x,y) .

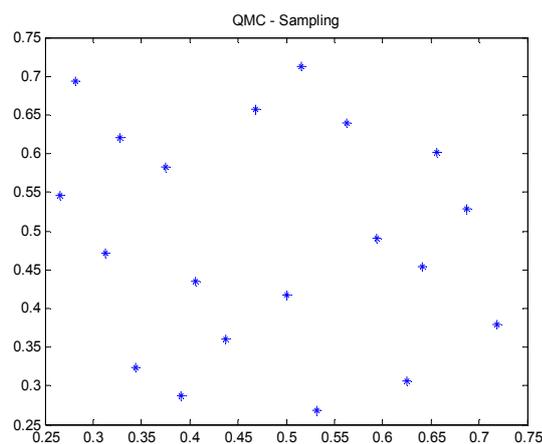


Figura 1 - Método Quase-Monte Carlo – QMC.

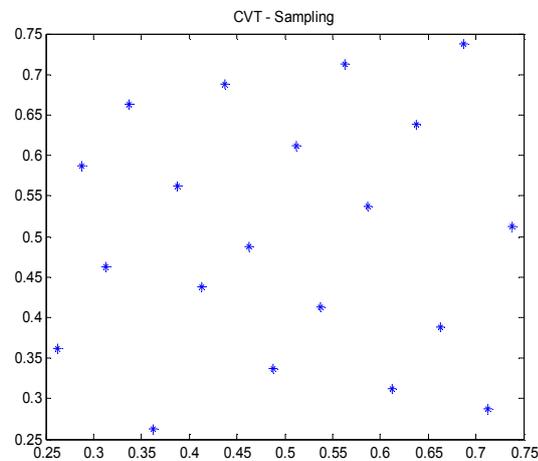


Figura 2 - Método Latin Centroidal Voronoi Tessellation – LCVT.

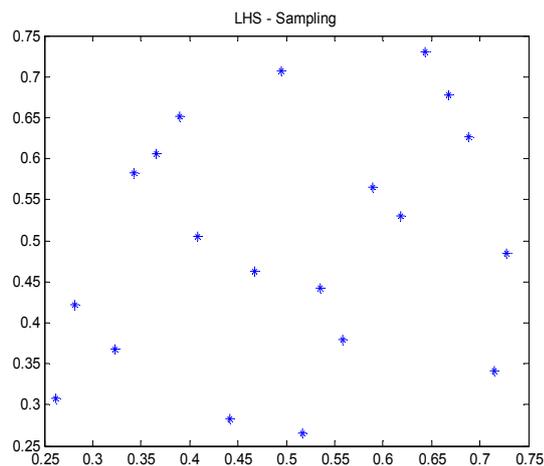


Figura 3 - Método Latin Hypercube Sampling – LHS.

As amostras LCVT e LHS resultaram em uma melhor distribuição. No entanto, apenas amostras do tipo LHS serão consideradas neste trabalho, porque resultado de estudos anteriores realizado por trabalho de pesquisa [07] para avaliação das amostras LHS, LCVT e QMC, demonstraram melhor resultado ao utilizar este tipo de amostra.

No método de amostragem hipercubo latino (LHS), desenvolvido por McKay, Conover, e Beckman em 1979, o domínio de cada variável aleatória x_k é di-

vidido em n intervalos $\Delta x_k^i (1 \cdots n)$, de igual probabilidade $\frac{1}{n}$ [27], onde $k = 1 \cdots m$ e m número total de pontos da amostra.

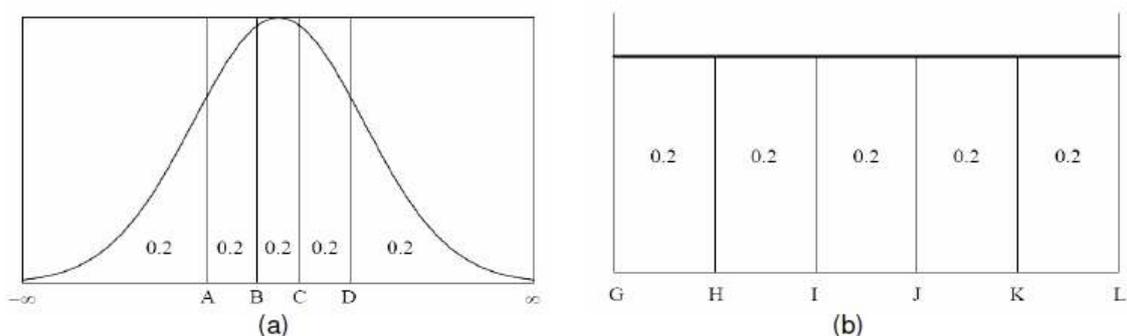


Figura 4 - Divisão em cinco intervalos do domínio de duas variáveis aleatórias (a) distribuição normal (b) distribuição uniforme (Penna, 2009).

Na Figura 4 são apresentadas duas variáveis aleatórias, uma tendo distribuição normal e outra, distribuição uniforme. Neste exemplo, o domínio de cada variável foi dividido em cinco intervalos.

O número de intervalos n deve ser igual ao tamanho da amostra desejada. Para cada intervalo é amostrado apenas um valor x_k^i , que para um valor i qualquer, são obtidos pela resolução da Equação (3.7) [33]:

$$\mathbf{F}_k(x_k^i) = \frac{i-1 + \mathbf{R}_i}{n} \quad (3.7)$$

Onde:

\mathbf{F}_k é a função de distribuição de probabilidade

\mathbf{R}_i representa uma distribuição uniforme no intervalo $[0,1]$

$$i = 1 \cdots n$$

A amostragem é realizada utilizando a transformada inversa da função de distribuição de probabilidade em questão, conforme:

$$(x_k^i) = \mathbf{F}_k^{-1} \left(\frac{i-1 + \mathbf{R}_i}{n} \right) \quad (3.8)$$

Para um melhor entendimento sobre o LHS, suponha uma distribuição bi-variada, onde uma variável tem distribuição normal e a outra uniforme. Na Figura 5 são apresentados os cinco valores sorteados para cada uma das variáveis, sendo que foi sorteado um valor para cada intervalo.

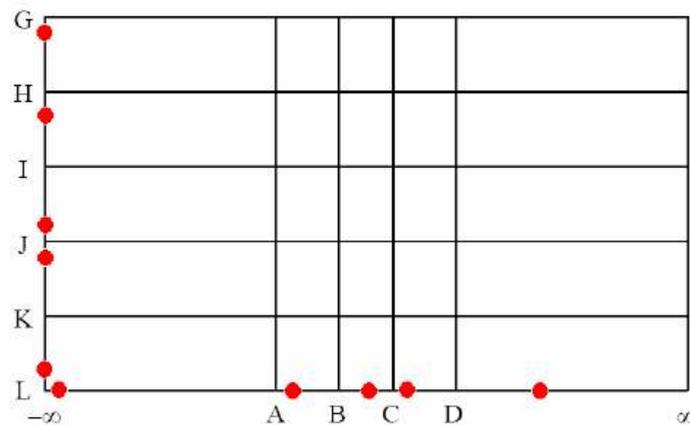


Figura 5 - Valores sorteados para cada variável (Penna, 2009).

Depois de obtidos os n valores para cada variável x_k , esses devem ser emparelhados de forma aleatória com os valores das demais variáveis. Dessa forma, são formados n vetores de dimensão m . A seleção aleatória do i -ésimo valor para cada variável é realizada mediante a permutação aleatória dos inteiros $1 \dots n$. Na Figura 6 é apresentada uma possível amostra de cinco pontos gerados utilizando a amostra LHS do exemplo anterior.

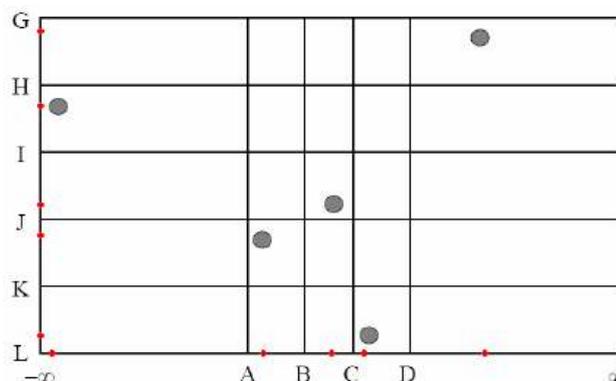


Figura 6 - Representação bi-dimensional de uma possível amostragem por LHS (Penna, 2009).

Observa-se que a amostra de n pontos da amostra do tipo LHS de dimensão m contém apenas um ponto em cada intervalo de cada uma das m variáveis.

3.2.3 Modelo de Regressão Polinomial

Regressão Polinomial, Kriging, Processo Gaussianos (GP), Redes Neurais Artificiais (ANN), Multivariate Adaptive Regression Splines (MARS), dentre outros, são métodos utilizados para construção de modelos substitutos (metamodelos) por ajuste de pontos, que são aproximações do tipo global que buscam aproximar o comportamento global da função. Neste estudo foram realizados testes com os métodos de Regressão Polinomial, Kriging e Processo Gaussianos. O modelo de Regressão Polinomial foi selecionado porque apresentou o melhor resultado em comparação com os outros dois.

Estatisticamente, usa-se o método de análise de regressão quando o problema envolve uma única variável dependente (resposta do modelo polinomial), considerada relacionado a duas ou mais variáveis independentes (variáveis do projeto), cujos valores são conhecidos, para prever os valores da variável dependente selecionada [10].

O modelo de regressão polinomial é uma extensão da regressão linear, ou seja, ocorre quando se adiciona termos polinomiais ao modelo básico de regressão linear.

Utiliza-se este modelo em duas situações:

1. Quando a função de resposta curvilínea verdadeira é realmente uma função polinomial.
2. Quando a função de resposta curvilínea verdadeira é desconhecida (ou complexa), porém, uma função polinomial é uma boa aproximação para a função verdadeira.

Neste projeto tem-se a segunda opção. Um perigo no uso de regressão polinomial é que sua extrapolação pode ser imprevisível, ou seja, pode assumir direções não esperadas quando extrapolados além do intervalo observado.

De acordo com a ferramenta de otimização (DAKOTA) utilizada neste trabalho, os modelos polinomiais podem ter a forma linear (primeira ordem), quadrático (segunda ordem) e cúbico (terceira ordem) [11].

Os modelos polinomiais, em geral, podem ter a forma linear (primeira ordem), quadrático (segunda ordem), cúbico (terceira ordem) ou de ordem “n” [11].

A forma do modelo polinomial linear é:

$$\hat{f}(\mathbf{x}) = \mathbf{c}_0 + \sum_{i=1}^n \mathbf{c}_i \mathbf{x}_i \quad (3.9)$$

Na forma do modelo polinomial quadrático teremos:

$$\hat{f}(\mathbf{x}) = \mathbf{c}_0 + \sum_{i=1}^n \mathbf{c}_i \mathbf{x}_i + \sum_{i=1}^n \sum_{j \geq i}^n \mathbf{c}_{ij} \mathbf{x}_i \mathbf{x}_j \quad (3.10)$$

E a forma do modelo polinomial cúbico é:

$$\hat{f}(\mathbf{x}) = \mathbf{c}_0 + \sum_{i=1}^n \mathbf{c}_i \mathbf{x}_i + \sum_{i=1}^n \sum_{j \geq i}^n \mathbf{c}_{ij} \mathbf{x}_i \mathbf{x}_j + \sum_{i=1}^n \sum_{j \geq i}^n \sum_{k \geq j}^n \mathbf{c}_{ijk} \mathbf{x}_i \mathbf{x}_j \mathbf{x}_k \quad (3.11)$$

Em todos os modelos polinomiais, $\hat{f}(\mathbf{x})$ é a resposta do modelo polinomial; os termos $\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_k$ são os componentes dos valores do parâmetro de projeto (variáveis preditoras) n-dimensionais; os termos $\mathbf{c}_0, \mathbf{c}_i, \mathbf{c}_j, \mathbf{c}_k$ são os coeficientes polinomiais, e n é o número de parâmetros de projeto.

O número de coeficientes n_c , depende da ordem do modelo polinomial e do número de parâmetros de projeto. Para o polinômio linear temos:

$$n_{linear} = n + 1$$

Para o polinômio quadrático temos:

$$n_{quad} = \frac{(n+1)(n+2)}{2}$$

E para o polinômio cúbico:

$$n_{cubico} = \frac{(n^3 + 6n^2 + 11n + 6)}{6}$$

A utilidade dos modelos polinomiais decorre de duas fontes: sobre uma pequena parcela do espaço de parâmetro, um modelo de baixa ordem polinomial é frequentemente uma aproximação exata às tendências dos dados verdadeiras e quando o procedimento dos mínimos quadrados fornece um ajuste de superfície que suaviza o ruído nos dados. Por esta razão, a estratégia de otimização baseada em aproximação muitas vezes é bem sucedida quando utiliza modelos polinomiais, particularmente o modelo quadrático [11].

3.2.4 Otimização por Aproximação Sequencial (SAO)

São aproximações do tipo local, que só são válidas em uma vizinhança próxima de onde as funções foram criadas. Serão consideradas como função substituta as funções baseadas no ajuste de pontos criado a partir do método da superfície de resposta.

Na otimização por aproximação sequencial, o algoritmo de otimização vai operar sobre um modelo substituto, de baixo custo computacional, ao invés de se fazer uso das respostas obtidas da simulação real, necessárias em diversas chamadas no processo de otimização. A construção deste modelo substituto implica em uma menor quantidade de chamada do simulador.

A Figura 7 descreve o fluxograma da estratégia de otimização por aproximação baseadas no ajuste de pontos, onde inicialmente será gerada uma amostra (conjunto de pontos) num espaço de projeto através da técnica de amostragem (Design of Experiments - DOE). Durante o processo de simulação será construído o modelo substituto (metamodelo) de acordo com o número de amostras definida inicialmente, e em seguida será iniciado o ciclo SAO que vai buscar minimizar a

função-objetivo da Equação (4.1). O capítulo 5 fornece maiores informações acerca deste processo.

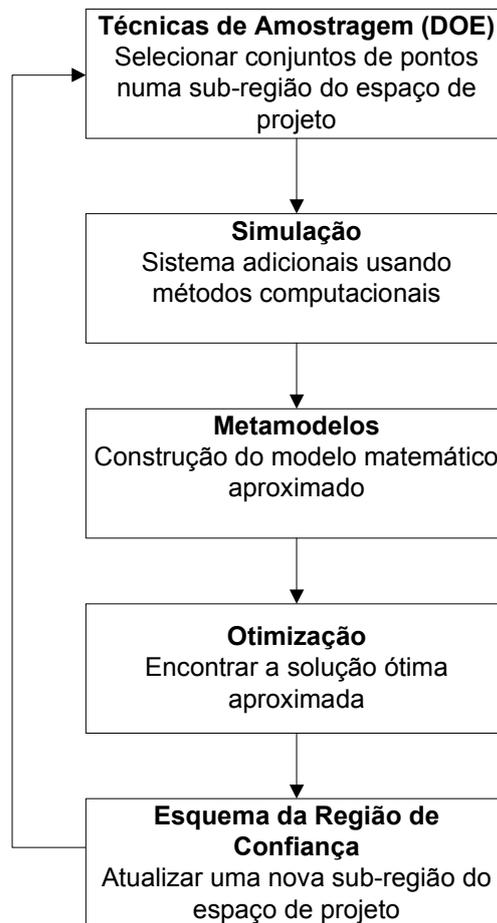


Figura 7 - Fluxograma da SAO.

O problema original de otimização é decomposto em uma sequência de subproblemas na metodologia SAO, que é limitada dentro de uma sub-região do espaço do projeto. A estratégia da Região de Confiança (RC) ou Trust Region é usada para controlar o processo de otimização a manter a exatidão aceitável entre o modelo substituto e o real (cara computacionalmente), onde as variáveis do projeto são atualizadas em cada subproblema (iteração SAO) [2].

Matematicamente cada subproblema de otimização pode ser descrito por:

$$\begin{aligned}
& \text{Minimize} && \widehat{f}^z(\mathbf{x}) \\
& \text{Sujeito à:} && \widehat{\mathbf{g}}_j^z(\mathbf{x}) \leq 0 \quad j = 1 \dots p \\
& && \widehat{\mathbf{h}}_k^z(\mathbf{x}) = 0 \quad k = 1 \dots q \\
& && \mathbf{x}_l \leq \mathbf{x}_l^z \leq \mathbf{x} \leq \mathbf{x}_u^z \leq \mathbf{x}_u
\end{aligned} \tag{3.12}$$

$$\begin{aligned}
\text{onde} \quad \mathbf{x}_l^z &= \mathbf{x}_c^z - \frac{\Delta^z}{2} \\
\mathbf{x}_u^z &= \mathbf{x}_c^z + \frac{\Delta^z}{2}
\end{aligned} \tag{3.13}$$

Os termos $\widehat{f}^z(\mathbf{x})$, $\widehat{\mathbf{g}}_j^z(\mathbf{x})$ e $\widehat{\mathbf{h}}_k^z(\mathbf{x})$ da Equação (3.12) são respectivamente a função substituta da função objetivo, da restrição de desigualdade e da restrição de igualdade.

onde:

\mathbf{x}_c^z = ponto central da região de confiança

Δ^z = tamanho da região de confiança

\mathbf{x}_l^z = limites inferiores da região de confiança

\mathbf{x}_u^z = limites superiores da região de confiança

z = número da iteração SAO

Durante o processo SAO em cada iteração z é definido um subproblema descrito nas equações (3.12) e (3.13). Na primeira iteração SAO ($z = 1$) é calculado inicialmente o tamanho da região de confiança (Δ^z), onde os limites iniciais da RC assumem um percentual do espaço do projeto, definido pelos limites inferiores e superiores da variável do projeto, já o ponto central da região de confiança (\mathbf{x}_c^z) assume o valor do ponto inicial da variável de projeto.

Ao resolver a Equação (3.12), um ponto ótimo aproximado \mathbf{x}_*^z é encontrado. Em seguida, é calculada a função real no ponto ótimo encontrado. A convergência é então verificada de acordo com os critérios adotados, se alcançada a

solução ótima é obtida e o processo é finalizado com sucesso. Caso contrário, o processo SAO continua com uma próxima iteração ($z = z + 1$) e a atualização de uma nova sub-região, através do esquema da região de confiança. Na próxima iteração é necessário determinar o próximo ponto central \mathbf{x}_c^{z+1} e o novo tamanho Δ^{z+1} para a nova sub-região, esses valores são determinados através de uma comparação entre os valores do ponto central \mathbf{x}_c^z e o ótimo \mathbf{x}_*^z da iteração corrente, conforme será descrito na Tabela 2.

Antes de começar a nova iteração $z + 1$, pode-se impor um fator de correção entre o modelo real e aproximado de modo à melhor a precisão do modelo substituto. O procedimento é então repetido até que o procedimento encontre a convergência do processo ou atinja-se o número máximo de iterações permitido [38].

Na Tabela 2 são apresentados os principais procedimentos implementados na estratégia SAO [38].

Tabela 2 – Procedimentos da estratégia SAO (Silva, 2009).

Etapas	Descrição
SAO 1.	Assumir o tamanho e ponto inicial da região de confiança;
SAO 2.	Computar as funções objetivo e restrições reais no ponto central da sub-região;
SAO 3.	Construir as funções substitutas (aproximadas) localmente para as funções objetivo e restrições;
SAO 4.	Otimizar o problema usando as funções aproximadas, onde as variáveis de projeto são limitadas pelas fronteiras da sub-região;
SAO 5.	Recalcular as funções objetivo e restrições reais no ponto ótimo encontrado;
SAO 6.	Verificar os critérios de convergência internos do otimizador:
6.1.	Se alcançada: o problema da iteração z está resolvido, continue com o processo.
6.2.	Caso contrário: a função aproximada não é adequada, o processo é finalizado.
SAO 7.	Manter/reduzir/aumentar a nova sub-região de acordo com o esquema da região de confiança;
SAO 8.	Impor (fator de correção) a consistência entre o modelo real e o substituto;
SAO 9.	Verificar os critérios de convergência global da estratégia SAO:
9.1.	Se alcançada: o projeto ótimo é obtido, o processo é finalizado com sucesso.
9.2.	Caso contrário: voltar para o passo SAO 3.

A figura abaixo ilustra um problema de otimização utilizando o processo iterativo e sequencial do esquema SAO. Os quadrados denotam uma sub-região de cada subproblema resolvido durante a iteração SAO. Os pontos dentro de cada sub-região são caracterizados pela amostras de dados, que são usadas para gerar um modelo substituto, no qual o algoritmo de otimização vai operar sobre um modelo substituto, ao invés do problema original [11].

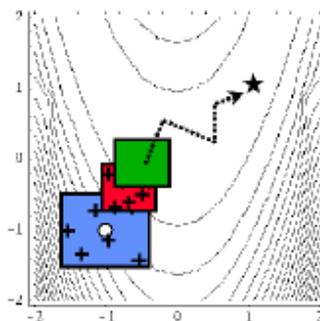


Figura 8 - Evolução do esquema SAO no problema de otimização [11].

Como já foi citado anteriormente, durante o processo SAO, pode ser estabelecida uma correção entre o modelo real e aproximado, que assegure a igualdade entre o modelo real e aproximado no ponto central de cada região de confiança de modo a melhorar a precisão do modelo substituto. Este procedimento assume a correção do tipo aditiva, multiplicativa ou função de correção combinada, sendo cada uma associada a diferentes níveis de correção, ou seja, de ordem zero, primeira ordem ou segunda ordem.

A cada subproblema (nova iteração SAO) será corrigido a partir da escolha de um nível de correção. O termo de correção será expresso por procedimentos baseados na expansão na série de Taylor.

Cada nível de correção será obtido a partir das considerações ou não dos termos da série de Taylor, ou seja, a ordem zero será apenas considerada o termo constante da série de Taylor, a primeira ordem é obtido a partir da ordem zero adicionado o termo da primeira derivada e a segunda ordem a partir da primeira ordem adicionado o termo da segunda derivada.

A correção de modelo substituto com o fator de correção aditiva e multiplicativa assume a seguinte forma:

$$\hat{f}(\mathbf{x}) = f(\mathbf{x}) + \alpha(\mathbf{x}) \quad (3.14)$$

$$\hat{f}(\mathbf{x}) = f(\mathbf{x})\beta(\mathbf{x}) \quad (3.15)$$

onde:

$\alpha(\mathbf{x})$ = Correção aditiva

$\beta(\mathbf{x})$ = Correção multiplicativa

De forma geral, $\alpha(\mathbf{x})$ e $\beta(\mathbf{x})$ podem ser calculados por aproximação na série de Taylor de primeira ou segunda ordem, conforme mostrado nas equações (3.16) e (3.17), respectivamente.

$$\alpha(\mathbf{x}) = A(\mathbf{x}_c) + \nabla A(\mathbf{x}_c)^T (\mathbf{x} - \mathbf{x}_c)$$

$$\alpha(\mathbf{x}) = A(\mathbf{x}_c) + \nabla A(\mathbf{x}_c)^T (\mathbf{x} - \mathbf{x}_c) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_c)^T \nabla^2 A(\mathbf{x}_c) (\mathbf{x} - \mathbf{x}_c) \quad (3.16)$$

$$\beta(\mathbf{x}) = B(\mathbf{x}_c) + \nabla B(\mathbf{x}_c)^T (\mathbf{x} - \mathbf{x}_c)$$

$$\beta(\mathbf{x}) = B(\mathbf{x}_c) + \nabla B(\mathbf{x}_c)^T (\mathbf{x} - \mathbf{x}_c) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_c)^T \nabla^2 B(\mathbf{x}_c) (\mathbf{x} - \mathbf{x}_c) \quad (3.17)$$

onde:

$$A(\mathbf{x}) = f(\mathbf{x}) - \hat{f}(\mathbf{x})$$

$$B(\mathbf{x}) = \frac{f(\mathbf{x})}{\hat{f}(\mathbf{x})}$$

$f(\mathbf{x})$ = função real

$\hat{f}(\mathbf{x})$ = função substituta

As correções de primeira ordem, tanto a aditiva como a multiplicativa, necessitam da primeira derivada, ou seja, dos gradientes, para a construção do modelo substituto, enquanto que as correções de segunda ordem necessitam do cálculo da segunda derivada, ou seja, da matriz Hessiana.

Conforme citado anteriormente durante o processo SAO, o esquema da região de confiança é necessário para atualizar o novo espaço de projeto em cada sub-região. Após cada iteração z do SAO, uma aproximação dá forma à relação da região da confiança através do termo de aceitação da função-objetivo ρ^z , que

mede a melhoria real em relação à prevista durante a otimização do modelo substituto.

$$\rho^z = \frac{f(\mathbf{x}_c^z) - f(\mathbf{x}_*^z)}{\widehat{f}(\mathbf{x}_c^z) - \widehat{f}(\mathbf{x}_*^z)} \quad (3.18)$$

Onde:

z = índice da iteração SAO

ρ^z = termo de aceitação da função-objetivo

\mathbf{x}_c^z = ponto central da sub-região z

\mathbf{x}_*^z = ponto ótimo da sub-região z

Uma vez calculado o termo ρ^z , o seu valor pode ser usado para definir a aceitação e o tamanho da próxima sub-região Δ^{z+1} de acordo com os critérios descrito na Tabela 3. O termo de aceitação ρ^z pode assumir um valor onde a região de confiança pode ser mantida, reduzida ou aumentada.

Tabela 3 - Termo de aceitação no esquema da região de confiança [11].

ρ^z	Precisão da Função Substituta	Resultado da Iteração	Tamanho da Região de Confiança
$\rho^z \leq 0$	Imprecisa	Rejeitar	Reduzir
$0 < \rho^z \leq 0.25$	Razoavelmente precisa	Aceitar	Reduzir
$0.25 < \rho^z < 0.75$ ou $\rho^z > 1.25$	Moderadamente precisa	Aceitar	Manter
$0.75 \leq \rho^z \leq 1.25$	Precisa	Aceitar	Aumentar

O novo ponto central \mathbf{x}_c^{z+1} da nova sub-região é também determinado em função do termo de aceitação e segue os critérios descritos pela Equação (3.19) abaixo:

$$\mathbf{x}_c^{z+1} = \mathbf{x}_*^z \quad \text{se } \rho^z \geq 0$$

$$\mathbf{x}_c^{z+1} = \mathbf{x}_c^z \quad \text{se } \rho^z < 0 \quad (3.19)$$

4 Ajuste de Histórico

O ajuste de histórico, no contexto do presente trabalho, consiste numa técnica que busca validar o modelo numérico de caracterização e escoamento usado num campo de petróleo já em produção. Seu principal objetivo é ajustar o modelo existente para que ele seja útil nas previsões de comportamento futuro e capaz de obter resultados coerentes com o histórico de produção do campo. Uma vez ajustado, esse modelo pode ser usado com maior confiabilidade na previsão de produção.

A técnica do ajuste de histórico dá-se por meio da simulação, a partir da qual o comportamento observado do reservatório obtido através de dados do campo, é comparado com o comportamento previsto para este reservatório proveniente da simulação computacional. Por meio desse processo, é possível melhorar o modelo computacional, uma vez que a comparação permite identificar a consistência dos dados e sugerir as mudanças necessárias. O ajuste de histórico pode ser uma ferramenta bastante útil na melhoria da caracterização do reservatório, possibilitando uma maior confiabilidade à fase de previsão de produção.

É comum os reservatórios de petróleo apresentarem limitações para a previsão de produção durante a fase de caracterização. Isso porque, nesse momento, diversas incertezas se fazem presentes, o custo para obter as informações é bastante elevado, e normalmente ocorre perda delas quando da passagem dos dados da escala geológica para a escala de simulação. Assim, o ajuste de histórico tem-se mostrado uma solução eficaz no contorno dessas dificuldades, ou seja, um mecanismo necessário.

4.1 Seleção das Variáveis de Projeto

Na maioria das vezes, a implantação do ajuste de histórico é difícil e trabalhosa, principalmente na fase inicial de exploração dos campos, quando ainda há poucos dados de produção disponíveis, o que aumenta as incertezas do processo. Nessa fase a confiabilidade do modelo ajustado diminui e o número de soluções possíveis aumenta. Por isso, fazem-se necessárias uma caracterização bem detalhada do campo e a obtenção de dados geológicos cada vez mais precisos.

Um dos problemas do ajuste de histórico é o grande número de simulações necessárias para calibrar um modelo numérico. Isso porque muitas variáveis críticas, que afetam diretamente os resultados, estão envolvidas no procedimento.

Este estudo serviu como experimento da metodologia desenvolvida e baseou-se num problema simples, que teve como principal objetivo estudar e avaliar as técnicas e os resultados gerados durante o processo de ajuste de histórico de produção, por este motivo que o critério de seleção das variáveis de projeto foi baseado em experiências anteriores.

Depois de selecionadas as variáveis de projeto, o próximo passo é estabelecer seus limites de variação (limite inferior e superior). Dessa forma, entre uma infinidade de combinações possíveis, o ajuste de histórico deve ser capaz de conduzir a um conjunto de parâmetros, dentro dos limites antes instituídos, que reproduz, de forma razoável, a maneira como o reservatório se comporta.

Neste estudo o parâmetro (propriedades do modelo a serem modificadas) escolhido foi a permeabilidade absoluta.

Caso o ajuste utilize mais de um parâmetro, pode-se estabelecer uma ordem dos parâmetros a serem modificados. Um dos métodos de priorização consiste em promover uma separação em termos do grau de incerteza das variáveis. Como variáveis com baixo grau de incerteza, podem ser consideradas, por exemplo, as propriedades dos fluidos — como a razão de solubilidade do componente gás na fase óleo, a viscosidade, etc. — e a pressão do ponto de bolha, se for utili-

zado um processo de amostragem confiável. Já as propriedades da formação do reservatório, como permeabilidade e porosidade, normalmente possuem maior grau de incerteza [19].

Mas essa não é uma regra geral. Os parâmetros considerados com maior grau de incerteza devem ser escolhidos caso a caso. Quando eles são variados individualmente dentro de seus limites, é possível escolher os parâmetros incertos e realizar uma análise de sensibilidade para examinar o comportamento do modelo. Esse exercício é capaz de indicar os parâmetros responsáveis por uma maior variação na resposta da simulação, além de indicar por onde o ajuste de histórico deve ser iniciado.

Portanto, é importante lembrar: ainda que o ajuste seja satisfatório para determinados parâmetros, não se pode considerar o modelo ajustado como o modelo real do reservatório. Vale ressaltar ainda que o ajuste de histórico não tem solução única, ou seja, mais de um conjunto de dados de entrada podem reproduzir o comportamento de um campo de petróleo, incluindo valores fisicamente inconsistentes.

4.2 Problema Inverso

O ajuste de histórico de produção é considerado um problema inverso, por meio do qual um conjunto de propriedades é determinado. O problema é considerado inverso porque o efeito é conhecido (parâmetros ajustados – vazão, pressão e saturação) e as causas são desconhecidas (propriedades dos modelos a serem modificadas – permeabilidade, porosidade, etc.). Essas propriedades devem reproduzir satisfatoriamente as informações dinâmicas disponíveis, como vazões, pressões e saturações.

A maior dificuldade do ajuste, como de todo problema inverso, é a multiplicidade de soluções. Afinal, um grande número de combinações de parâmetros

pode fornecer respostas parecidas entre si, principalmente quando seu grau de incerteza é elevado.

Quando o período de histórico é pequeno, esse problema tende a se agravar ainda mais. Apesar de diferentes soluções confirmarem razoavelmente as observações registradas, qualquer uma delas poderia gerar uma previsão diferente e conduzir a uma faixa com distintas respostas.

Para minimizar esse problema, seguem algumas regras:

1. Durante a fase de caracterização do reservatório, antes de construir o modelo de simulação, obter o máximo de informações.
2. Definir limites de variação para todos os parâmetros.
3. Não variar os parâmetros além dos limites de variação preestabelecidos. Se esse procedimento for indispensável, refazer toda a análise para o parâmetro em questão.
4. Variar primeiro os parâmetros com menor grau de confiabilidade.

4.3 Ajuste Manual e Assistido

Normalmente, os ajustes de produção são feitos por meio de tentativas e erros, em que os parâmetros a serem utilizados são escolhidos com base na experiência de ajustes anteriores. Caso o ajuste não atinja um resultado satisfatório, o processo é reiniciado com a escolha de outro parâmetro. Após diversas repetições, espera-se chegar a um ajuste aceitável.

Há duas formas para proceder a um ajuste: a manual e a assistida. Em geral, o chamado ajuste manual é mais trabalhoso para o profissional envolvido no processo. Isso porque todas as tarefas, tais como execução das simulações, alterações do modelo de simulação e análise dos resultados, são realizadas manualmente, exigindo do profissional mais esforço, maior interação com o processo e mais tempo de trabalho. Já o chamado *ajuste assistido* utiliza-se da automatização das tarefas manuais, sendo menos trabalhoso e, ao mesmo tempo, mais confiável,

pois investiga melhor o espaço de soluções. Essa forma de ajuste aproveita a experiência do profissional e possibilita a sua interação com o processo, permitindo-lhe proceder ao ajuste por etapas. Além disso, para se encontrar a melhor combinação de parâmetros (variáveis do projeto) que minimize a função-objetivo, utiliza-se um algoritmo de otimização.

Nas décadas de 1970 e 1980, propuseram-se inúmeros trabalhos que visavam à automatização do ajuste de histórico de produção [34]. Apesar disso, o uso generalizado dessa ferramenta não se difundiu como o esperado. Para explicar esse comedimento, algumas razões podem ser apontadas, tais como: a multiplicidade de soluções (mau-condicionamento), comum nos problemas inversos; o comportamento altamente não-linear da função-objetivo, ou seja, problemas em que não há uma relação direta entre as variáveis de entrada (variáveis do projeto) e a variável de saída (função-objetivo), o que dificulta a convergência dos métodos de otimização ou a torna bastante lenta; a ocorrência de oscilações da função-objetivo, que podem provocar a interrupção prematura do cálculo dos parâmetros em pontos de “mínimo local” que não satisfazem às exigências do problema; a existência de longos vales quando variáveis de pequena sensibilidade são incluídas no processo; o grande esforço computacional requerido, que inviabiliza a utilização do processo em estudos de grande porte; etc [19].

Assim, o ajuste assistido foi abandonado por algum tempo até que, recentemente, com o avanço dos computadores, de técnicas de computação paralela, técnicas de otimização e construção de modelo matemático aproximado, ele tem ressurgido, sendo largamente utilizado. Diversos trabalhos que utilizam esse modelo têm como proposta a automatização de várias etapas do ajuste, resultando em um processo mais rápido, menos frustrante e com melhores resultados.

4.4 Seleção dos Algoritmos de Otimização

No ajuste de histórico, os algoritmos de otimização são utilizados para se buscar a melhor combinação de parâmetros, ou seja, a que minimize a função-objetivo relacionada com o erro entre o valor observado e calculado. Vários métodos e algoritmos de otimização têm sido usados, pois é difícil haver um único método ou algoritmo que funcione bem em todos os casos.

Existem duas categorias básicas de algoritmos geralmente usados no ajuste de histórico de produção. A primeira é baseada no método de gradientes, que consiste no cálculo das derivadas da função-objetivo e restrições. Sua principal limitação diz respeito à quantidade de variáveis possíveis de serem estudadas, que normalmente é bastante reduzida. Isso porque esse método demanda alto custo computacional, em termos de tempo de CPU, e apresenta certa limitação de desempenho para funções-objetivos muito irregulares, além disto, muitos simuladores não fornecem gradientes. A segunda categoria são os algoritmos de busca direta, que não requerem o cálculo de gradientes, já que utilizam apenas valores das funções. Esses métodos normalmente indicados para situações em que a superfície da função-objetivo não é suave (derivadas descontínuas) ou quando o cálculo numérico de derivadas exige um grande esforço computacional.

É necessário chamar a atenção para o fato de o algoritmo ser tão somente uma ferramenta auxiliar no ajuste de histórico. Ele é capaz de automatizar e agilizar as etapas mais repetitivas do processo, mas não pode ser encarado como uma rotina capaz de obter o ajuste de forma totalmente automática.

Por isso, se pouco ou nenhum progresso estiver sendo obtido na redução da função-objetivo, é importante que o engenheiro acompanhe constantemente o processo e julgue-o, a fim de definir as possíveis alterações de rumo. Nesses casos, as variáveis do problema ou os seus limites de variação devem ser cuidadosamente revistos. Uma vez executando essas tarefas, o profissional pode excluir propriedades de pequena sensibilidade ou incluir novas variáveis que ainda não

havam sido consideradas. Além disso, pode rever as tolerâncias usadas no processo.

Se a função-objetivo é reduzida a um limite abaixo da tolerância preestabelecida e/ou se o modelo ajustado atende aos objetivos do estudo, a solução é considerada satisfatória. Por outro lado, mínimos locais ou falhas específicas dos algoritmos de otimização costumam provocar soluções insatisfatórias.

A qualidade do ajuste pode ser influenciada de diversas formas: por meio da redução da função-objetivo, do número de simulações, da incerteza envolvida no processo de caracterização e do número de propriedades.

A Figura 9 ilustra as etapas do ajuste de histórico apresentadas no decorrer deste capítulo.

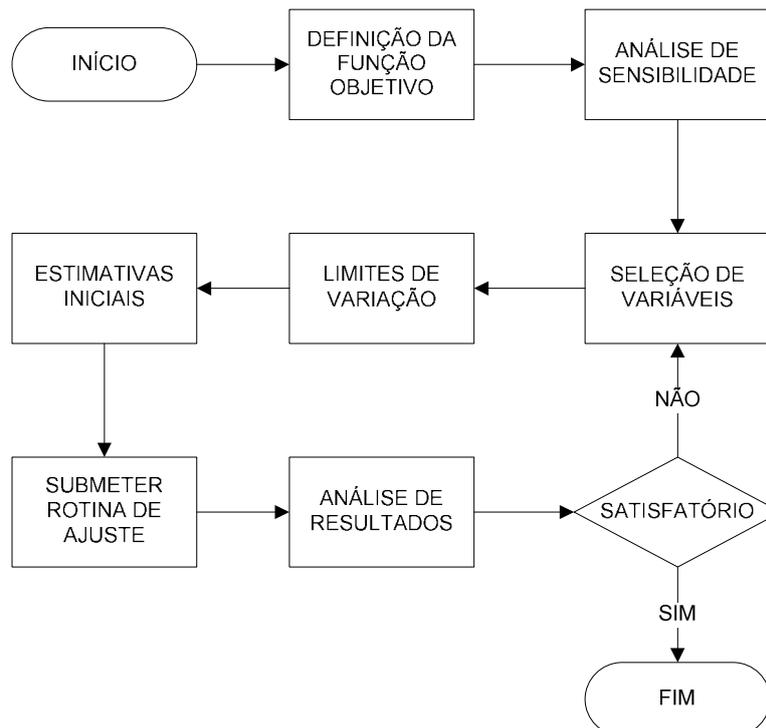


Figura 9 - Etapas do Ajuste de Histórico (Leitão, 1997).

4.5 Formulação do problema

A função-objetivo, as variáveis de projetos e restrições são elementos que constituem um problema de otimização. Para cada elemento será apresentado o seu papel e significados mais gerais abordados no problema aqui proposto, bem como a metodologia utilizada no processo do ajuste de histórico de produção. Esses elementos estão descritos adiante.

4.5.1 Função-Objetivo

O primeiro passo a ser realizado em qualquer processo de ajuste de histórico de produção é definir o que será ajustado (por exemplo, dados de pressão e produção do poços). Depois de definido, é possível compor a função-objetivo, que expressa matematicamente a diferença entre os dados calculados e observados.

Para ajustar as produções de óleo, água ou gás, a seguinte função-objetivo é definida [16]:

$$f(\mathbf{x}) = \sqrt{\sum_{j=1}^n \left[\log \left[\frac{PA_j^{Observado}}{PA_j^{Calculado}} \right] \right]^2} \quad (4.1)$$

onde:

$PA^{Observado}$ = Produção acumulada dos dados observados da série de dados (por exemplo, dados de produção de óleo, água ou gás dos poços) ao longo do tempo

$PA^{Calculado}$ = Produção acumulada dos dados Calculados da série de dados (por exemplo, dados de produção de óleo, água ou gás dos poços) ao longo do tempo

n = Número de dados Observados e Calculados de cada série de dados

4.5.2 Variáveis de Projeto

Uma vez definida a função-objetivo, o passo seguinte consiste da seleção de um conjunto de variáveis a serem alteradas no modelo para obtenção do ajuste desejado. De modo geral, qualquer propriedade ou “conjunto” de propriedades (por exemplo, toda a malha de permeabilidades) pode ser considerado como parâmetro.

Em princípio, devem-se escolher apenas as variáveis que apresentem forte influência sobre a função-objetivo, pois a inclusão de incógnitas desnecessárias torna o processo mais lento e ineficiente.

A permeabilidade absoluta é a variável de projeto selecionada para o problema tratada nesse estudo.

Os estudos foram aplicados a dois ajustes de características distintas, representados por um campo de permeabilidade com três regiões distintas e um campo de permeabilidade estocástico.

4.5.3 Restrições de Limite

Além de identificar as variáveis a serem consideradas no processo, é preciso estimar limites máximos e mínimos associados a cada uma ($\mathbf{x}_i^l \leq \mathbf{x}_i \leq \mathbf{x}_i^u$). Estes limites delimitam o espaço do projeto, assim como evita que os algoritmos de otimização forneçam resultados fisicamente incorretos, tais como valores negativos ou muito diferentes dos esperados para o campo.

Para obter tais limites, foi realizado um estudo paramétrico para encontrar os dados que representam uma maior confiabilidade no modelo numérico do reservatório.

5 Implementação Computacional

5.1 Ferramentas

Neste capítulo serão apresentadas as ferramentas utilizadas no presente trabalho. A estrutura do sistema é formada por programas complementares implementados, utilizando o software OCTAVE, que irão trabalhar integrados ao framework DAKOTA e simulador IMEX.

5.1.1 IMEX

O IMEX [08] foi programado em FORTRAN 77 e pode ser executado sob diferentes plataformas: mainframes IBM, CDC, CRAY, Honeywell, DEC, Prime, Gould, Unisys, Apollo, SUN, HP, FPS, IBM-PC 486, e família Intel Pentium.

O simulador IMEX possui três solvers distintos: explícito, implícito ou adaptativo. Estes referem-se à forma como são resolvidas as equações não-lineares dos modelos de fluxo. No caso de modo explícito, o passo de tempo utilizado deve ser sempre menor que o máximo valor de passo que mantenha a estabilidade do sistema. No modo implícito, é necessário resolver um sistema de equações não lineares a cada passo, podendo ser escolhidos passos maiores e o modo adaptativo permite escolher entre a solução implícita ou explícita segundo a característica das variações dos estados do sistema.

No IMEX a comunicação com o usuário pode ser efetuada através de arquivos de entrada e saída. O usuário deve criar um arquivo texto de entrada (formato .DAT) que contém: a configuração da malha, informação geológica, tipo de fluxo de óleo, condições iniciais, métodos numéricos, lista de poços, entre outras

informações. O simulador, após a execução, fornece os valores de saída em um grupo de arquivos, tal como indicado na Figura 10.

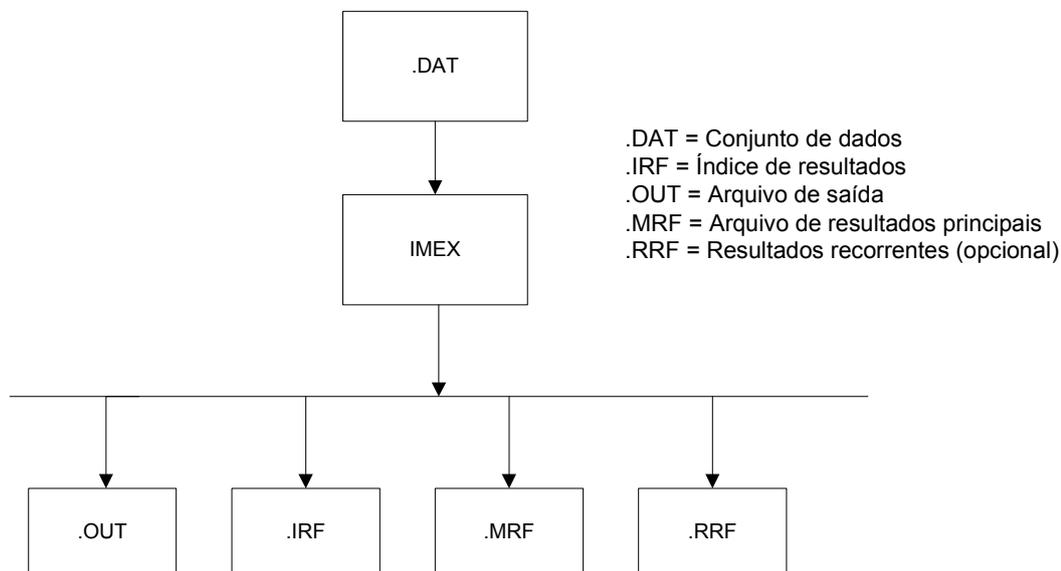


Figura 10 - Arquivos de entrada e saída do IMEX.

O Arquivo .DAT é imprescindível, uma vez que este arquivo contém todas as informações que definem a configuração completa do reservatório a ser simulado. A informação contida no arquivo .DAT está classificada em 7 tipos de dados:

1. Dados de controle de Entrada e Saída
2. Dados de descrição do reservatório
3. Propriedades dos componentes
4. Dados de Rochas e Fluidos
5. Condições Iniciais
6. Informação sobre os métodos numéricos
7. Informação dos poços e dados recorrentes.

Os arquivos .MRF e .IRF contêm os resultados globais da simulação, isto é, valores das vazões de óleo, gás, água etc. O arquivo .IRF contém o índice dos

resultados e o arquivo .MRF armazena os resultados numéricos em si. O arquivo .OUT armazena resultados escolhidos pelo usuário, no formato ASCII.

O comando *INCLUDE permite ao simulador quebrar a leitura sequencial do arquivo de entrada .DAT primário para começar a leitura de um arquivo secundário. Uma vez finalizada a leitura do segundo arquivo, continua-se com a leitura a partir da linha seguinte a que continha o comando *INCLUDE. O formato do comando é o seguinte:

```
*INCLUDE 'arquivosec'
```

Este comando facilita a alteração de algumas partes do arquivo .DAT sem afetar o resto, ou seja, se num arquivo secundário estiverem os dados referentes as definições dos poços (tipo de poços, locações, geometria, parâmetros físicos, restrições, cronograma), caso haja necessidade de alteração dessas definições apenas ele precisaria ser modificado. Com esta estratégia, as mudanças referentes ao processo de ajuste de histórico serão fornecidas em um arquivo pequeno, ao invés de se precisar criar arquivos .DAT completos

5.1.2 DAKOTA

O DAKOTA (Design Analysis Kit for Optimization and Terascale Applications) foi um projeto iniciado em 1994 como uma investigação interna e atividade de desenvolvimento no laboratório Sandia Nacional em Albuquerque, Novo México. O objetivo original deste projeto era fornecer um conjunto comum de ferramentas de otimização para um grupo de engenheiros que estavam resolvendo análise estrutural e projeto de vários problemas [11].

O DAKOTA é um framework que fornece uma interface flexível e extensiva entre seu código de simulação e uma variedade de estratégias e métodos iterativos. Este sistema inicialmente foi concebido como uma interface de uso fácil entre

os códigos de simulação e algoritmos de otimização. No entanto versões mais recentes foram expandidas para implementar interfaces com outros tipos de métodos de análise iterativos tais como, a quantificação de incertezas com métodos não determinísticos de propagação, estimativa de parâmetros com o método dos mínimos quadrados, análise de sensibilidade/variância em projetos de experimentos de aplicações gerais, e estudos paramétricos. Estas potencialidades podem ser usadas em seus próprios blocos ou em blocos construídos com estratégias mais sofisticadas tais como, otimização híbrida, otimização baseada em aproximação, programação linear e não-linear, ou otimização sob incerteza [11].

O DAKOTA foi desenvolvido sob o paradigma da orientação a objetos, com a finalidade de utilizar abstrações dos componentes chaves requeridas para análise iterativa do sistema.

Entretanto, uma das vantagens que o DAKOTA oferece é o acesso a uma escala muito abrangente de potencialidades iterativas que podem ser obtidas através de uma única interface relativamente simples entre o DAKOTA e o código do simulador fornecido pelo usuário. Esta interface é descrita como uma “caixa-preta” porque o DAKOTA não necessita do acesso ao código fonte do sistema de simulação. A troca de informações entre o DAKOTA e o simulador é realizada através da leitura e escrita em um arquivo de dados. Para a utilização de um tipo diferente de método ou de estratégia iterativa com o simulador, faz-se necessário apenas a mudança de alguns comandos de entrada no DAKOTA e dar início a uma nova análise. Esta interface é descrita na figura a seguir:

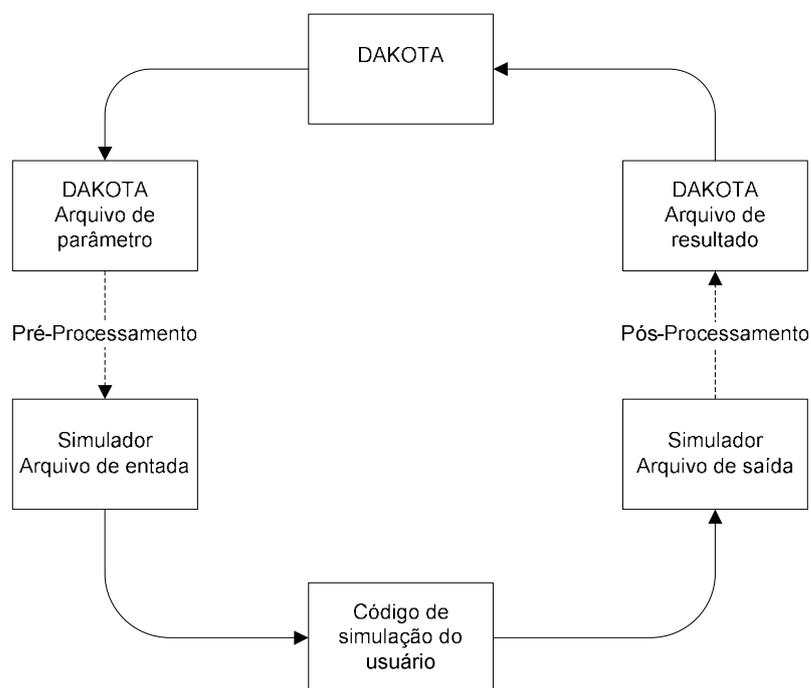


Figura 11 - Interface entre o DAKOTA e o Simulador (Dakota Version 5.0 User's Manual).

Uma dos passos do esquema do ajuste de histórico aqui desenvolvido é a configuração do arquivo de entrada (script) do DAKOTA, que contém os parâmetros necessários para o funcionamento do processo, tais como estratégia, variáveis, interface, métodos e modelos. A seguir serão apresentados os principais controles do DAKOTA utilizados neste trabalho no processo do ajuste de histórico.

5.1.2.1 Estratégia de Otimização no DAKOTA

O problema de otimização será solucionado através do algoritmo SQP, que é identificado no arquivo de entrada do DAKOTA através do método *np-sol_sqp*, que pertence ao pacote externo NPSOL, onde é implementado pela classe *NPSOLOptimizer*.

O NPSOL foi criado por Philip Gill, Walter Murray, Michael Saunders e Margaret Wright [32]. Foi construído com um conjunto de subrotinas em Fortran

77, projetado para resolver problemas de otimização não linear, onde as funções devem ser suaves, mas não necessariamente convexas. O NPSOL são métodos baseados na programação quadrática sequencial. Este algoritmo SQP apenas necessita das primeiras derivadas - quando estas não são fornecidas podem ser estimadas por algum procedimento numérico para análise de sensibilidade.

No DAKOTA, há dois tipos de controles: os independentes e os dependentes do método NPSOL. Nas Tabelas 4 e 5 são apresentados alguns destes controles.

Tabela 4 – Controles independentes do método NPSOL.

Controle	Descrição
max_ iterations	Limita o número máximo das iterações do SQP
max_function_evaluations	Limita o número máximo de avaliações de função que podem ser executadas durante a otimização
constraint_tolerance	Define como as funções de restrições são satisfeitas na convergência. O valor padrão é dependente da precisão da plataforma da máquina em uso, mas geralmente é da ordem de 1e-8. Valores extremamente pequenos para constraint_tolerance podem não ser atingidos
convergence_tolerance	Define a tolerância de otimalidade interna do NPSOL que é usada na avaliação se uma iteração satisfizer as condições de Kuhn-Tucker de primeira ordem para um mínimo. A magnitude da tolerância à convergência, especifica aproximadamente o número de dígitos significativos da precisão desejada na função objetivo final (por exemplo, convergence_tolerance=1e-6 irá resultar em aproximadamente 6 dígitos de precisão na função objetivo final)
output_verbosity (silent quiet verbose debug)	Controla a quantidade de informação gerada em cada iteração principal SQP. As configurações silent e quiet resultam em apenas uma linha de saída de diagnostico para cada iteração principal e imprime a solução da otimização final. As configurações verbose e debug adicionam informação sobre a função objetivo, restrições e variáveis em cada iteração principal

Tabela 5 – Controles dependentes do método NPSOL.

Controle	Descrição
verify_level	Controla instruções NPSOL para executar verificação de diferença finita no componente do gradiente fornecido pelo usuário
function_precision	Fornecer uma estimativa da precisão para a qual as funções do problema podem ser calculadas
linesearch_tolerance	Controla a precisão da busca linear. Quanto menor o valor (entre 0 e 1), mais precisamente o NPSOL irá tentar calcular um mínimo preciso ao longo da direção de busca

5.1.2.2 Implementação da Estratégia de Otimização Aproximada Sequencial (SAO) no DAKOTA

A estratégia de Otimização Aproximada Sequencial (SAO) é identificada no arquivo de entrada do DAKOTA através do método *surrogate_based_local*, que é implementado pela classe *SurrBasedLocalMinimizer*.

No arquivo de entrada do DAKOTA o usuário pode controlar o método *surrogate_based_local* através dos controles abaixo:

Tabela 6 – Controles SAO no DAKOTA.

Controle	Descrição
approx_method_pointer	Ponteiro do método aproximado do subproblema minimizado
Approx_method_name	Nome do método aproximado do subproblema minimizado
max_iterations	Número máximo de iterações do SAO
convergence_tolerance	Tolerância usada em avaliações internas da convergência do SAO
soft_convergence_limit	Controle suave da convergência para as iterações do SAO, que limita número de iterações consecutivas com menos melhoria que a tolerância da convergência
truth_surrogate_bypass	Flag para ignorar todos os níveis inferiores da aproximação ao executar verificações reais em um nível superior da aproximação

O usuário tem a opção de controlar a região de confiança através da especificação do grupo identificado pela palavra chave *trust_region*. Esses controles podem ser visualizados com maiores detalhes na tabela abaixo.

Tabela 7 – Controle da Região de Confiança no DAKOTA.

Controle	Descrição
<code>initial_size</code>	Tamanho inicial da região de confiança (relativo ao limite)
<code>minimum_size</code>	Tamanho mínimo da região da confiança
<code>contract_threshold</code>	Fator de contração do tamanho da região de confiança que é usado quando o modelo substituto esta sendo impreciso. Caso a relação da região de confiança esteja abaixo deste valor, a região de confiança é contraída
<code>expand_threshold</code>	Fator de expansão do tamanho da região da confiança que é usado quando o modelo substituto esta sendo preciso. Caso a relação da região de confiança esteja acima deste valor, a região de confiança é expandida
<code>contraction_factor</code>	Fator de contração da região de confiança
<code>expansion_factor</code>	Fator de expansão da região de confiança

Os comando *contraction_factor* e *expansion_factor* são relacionados ao que é chamado a razão da região da confiança, que é a real diminuição (decréscimo) no modelo real pelo decréscimo que foi previsto no modelo real na atual região de confiança. O comando *contract_threshold* ajusta o valor mínimo aceitável para a relação da região de confiança, isto é, valores abaixo deste ponto inicial causam o encolhimento da região de confiança para a próxima iteração do SAO.

O comando *expand-threshold* determina o valor acima da região da confiança, que região de confiança expandirá para a próxima iteração do SAO.

Na estratégia SAO o fator de correção entre o modelo real e aproximado é identificado no arquivo de entrada do DAKOTA através da palavra chave *correction*, que pode assumir o valor *additive* ou *multiplicative* ou *combined*, associados a *zeroth_order* ou *first_order* ou *second_order*. O comportamento padrão é que nenhum fator de correção seja aplicado, mas na nossa implementação foi selecionado o valor *additive* com *zeroth_order*.

O método de regressão polinomial da forma quadrática será identificado no DAKOTA pela palavra chave *polynomial quadratic*.

5.1.3 OCTAVE

O OCTAVE [22] é uma linguagem de programação de alto nível, destinada ao tratamento de problemas para computação numérica. É uma aplicação desenvolvida utilizando uma filosofia *OpenSource* (software livre).

O OCTAVE pode efetuar cálculos aritméticos com reais, escalares, complexos e matrizes; resolver sistemas de equações algébricas; integrar funções sobre intervalos finitos e infinitos e integrar sistemas de equações diferenciais ordinárias e diferenciais algébricas.

O OCTAVE é em grande parte compatível com o MATLAB. É uma ferramenta desenvolvida para o sistema operacional Linux, sendo atualmente distribuída com as principais versões deste sistema operacional. A sua utilização no ambiente Windows é igualmente possível através da utilização da ferramenta CYGWIN, a qual fornece um ambiente de emulação da plataforma Linux sobre Microsoft Windows.

5.2 Metodologia

A metodologia proposta neste trabalho consiste em desenvolver um mecanismo para automatizar o processo de ajuste de histórico de produção em simulação numérica de reservatório por um ajuste assistido, através da minimização matemática de uma função-objetivo por um método de otimização baseada em aproximação Sequencial (SAO).

De acordo com o número de variáveis de projeto, será gerada uma amostra de dados para o cálculo da função-objetivo, representando a função real que será a base para construção do modelo substituto.

Para a geração das amostras foi utilizada a técnica de amostragem (Design of Experiments – DOE) Hipercubo Latino (LHS).

Será utilizada uma estratégia de aproximação, no qual o algoritmo de otimização vai operar em um modelo substituto, de baixo custo computacional, ao invés da simulação do modelo envolvendo a física complexa. A função aproximada foi construída utilizando o modelo de regressão polinomial quadrática.

Uma vez que o modelo substituto é construído, um modelo barato para as respostas obtidas será usado ao invés de se fazer uso das respostas obtidas da simulação real, necessárias em diversas chamadas no processo de otimização.

Para a minimização matemática da função-objetivo, que representa a norma da diferença entre um histórico de produção observado e um histórico obtido através da simulação computacional, será adotada uma estratégia SAO (Sequential Approximation Optimization).

O período de produção do reservatório é dividido em um número finito de etapas de tempo. Como o simulador só encerra a execução quando encontra o primeiro critério de parada, o tempo pode variar de acordo com o modelo selecionado. Para solucionar este problema, foi necessário encontrar o valor da produção observada e calculada no mesmo período de tempo utilizados no cálculo da função-objetivo. Primeiramente foram gerados 192 pontos entre o tempo inicial e o final da produção observada. Os 192 números de pontos foram baseados numa média de tempo total de produção de cada arquivo de saída gerado durante o processo de simulação. O valor destes pontos (tempo de produção) foi utilizado para encontrar a produção.

Para encontrar o valor da produção nestes pontos utilizou-se uma interpolação por spline cúbica, através da função abaixo:

$$yy = spline(x, y, xx)$$

onde:

yy - valor da produção em relação ao tempo xx

x - tempo da produção

y - valor da produção

xx - valor do tempo aonde se deseja a produção

Uma spline cúbica é uma curva suave construída passando através do conjunto de pontos. A curva entre cada par de pontos é determinada por um polinômio do terceiro grau, que é calculado para fornecer uma curva suave entre os pontos.

As splines são excelentes curvas interpoladoras, devido ao fato de serem bastante suaves e, além disso, são bastante viáveis computacionalmente porque não exigem a resolução de sistemas lineares muito grandes e também evitam certas oscilações indesejadas, que é o que ocorre quando se utilizam polinômios de graus maiores para efetuar a interpolação.

No modelo numérico de campos de petróleo construído serão testadas as diferentes situações de restrições de poço. Em cada uma das quatro situações as restrições no Water CUT (corte de água) e/ou BHP (pressões de fundo de poço) são ativadas ou não.

A estrutura do sistema é formada pelo desenvolvimento de programas utilizando a linguagem OCTAVE, que irão trabalhar integrados ao DAKOTA e IMEX. Esses programas adicionais tem como finalidade prover uma interface entre o DAKOTA e o IMEX, realizando um tratamento prévio das informações fornecidas pelo DAKOTA para manipulação pelo IMEX, e vice-versa. Além disso, foram desenvolvidos também programas com finalidades específicas, a exemplo do cálculo da função-objetivo, geração do arquivo de entrada do IMEX e outros.

A Figura 12 apresenta o esquema do ajuste de histórico assistido. Para um melhor entendimento, descrevemos abaixo a seqüência de passos desse fluxo de execução:

1. INICIO – O fluxograma do ajuste de Histórico inicia-se com a execução de um arquivo de entrada do DAKOTA;
2. Arquivo de Entrada do DAKOTA - É um arquivo de configuração (.in) para entrada no DAKOTA com informações tipo: estratégia, variáveis, interface, métodos e modelos;

3. Arquivo de Parâmetros do DAKOTA - É um arquivo gerado pelo DAKOTA com informações que serão usadas pelo conjunto de programas da rotina de Pré-Processamento para a geração do arquivo de entrada no IMEX;
4. Programa OCTAVE Pré-Processamento - O programa analisador (principal) irá executar uma rotina em OCTAVE chamada de pre-processador, que tem a função de criar o arquivo de entrada do IMEX a partir da leitura de um arquivo de TEMPLATE e dos parâmetros gerado pelo DAKOTA;
5. Arquivo de Entrada do IMEX – Arquivo gerado pelo programa pré-processado a partir do arquivo de TEMPLATE;
6. Arquivo de Saída do IMEX – É um arquivo resultante da execução do arquivo de entrada do IMEX no programa analisador, onde nele constam os valores da produção acumulada da superfície (óleo, água e gás);
7. Programa OCTAVE Pós-Processamento - É uma rotina em OCTAVE que é executada pelo programa analisador, que terá a função de ler o arquivo de saída do IMEX para obter o valor da produção acumulado da superfície ao longo do tempo. Com estes dados o programa irá calcular a função-objetivo;
8. Arquivo de Resultado do DAKOTA - É um arquivo contendo os valores do ajuste de histórico de produção calculados pelos programas de Pós-Processamento.
9. FIM – O fluxograma finaliza sua execução quando o DAKOTA encontrar a solução ótima do problema.

O cálculo da função-objetivo é feito através da Equação (4.1) descrita no item 4.51. Durante a execução, será construído o modelo substituto de acordo com o número de amostras definidas no arquivo de entrada e será iniciado o ciclo SAO (Sequential Approximation Optimization) que vai procurar por um ponto ótimo aproximado. O ciclo é repetido diversas vezes, até que o ajuste de histórico de produção seja considerado satisfatório, ou outro critério de convergência tenha

tido satisfeito. Se convergir, o processo é encerrado e o último ponto ótimo obtido é considerado como solução ótima do problema; caso contrário, será iniciada uma nova iteração a partir da geração de novos parâmetros.

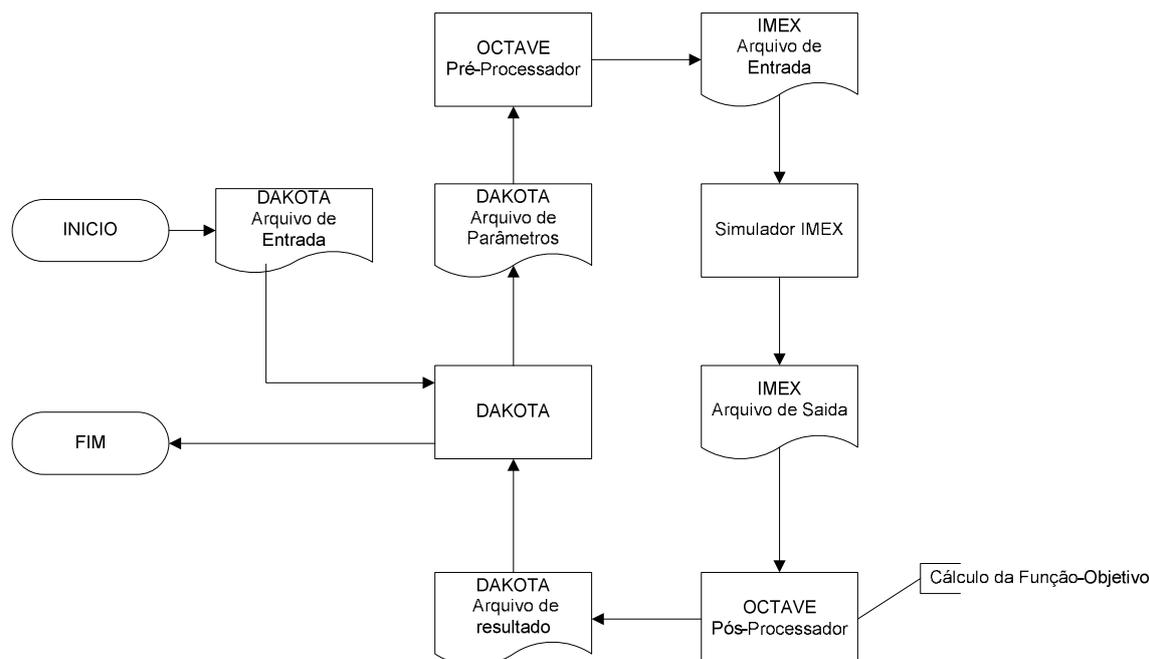


Figura 12 - Esquema do ajuste de histórico assistido implementado neste trabalho.

5.3 Scripts - Programas Adicionais

Para o funcionamento do esquema do ajuste de histórico foram desenvolvidos programas adicionais na linguagem OCTAVE. Esses scripts têm como objetivo complementar a estrutura do sistema através de rotinas específicas necessárias à solução do sistema, além de prover uma interface entre o DAKOTA e o IMEX, realizando um tratamento prévio das informações fornecidas pelo DAKOTA para manipulação pelo IMEX, e vice-versa.

Os scripts são executados a partir de um programa principal `analysisDriver.m`, demonstrado na figura abaixo:

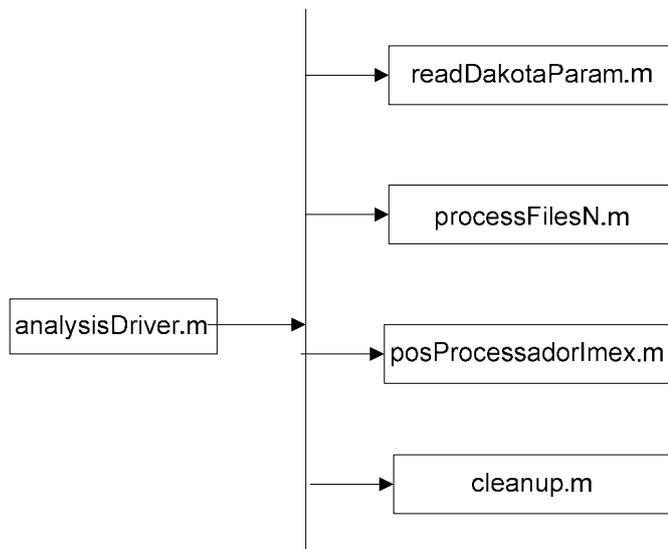


Figura 13 - Fluxograma dos Scripts.

Os scripts estão divididos em dois grupos:

- Pré-Processamento
- Pós-Processamento

O primeiro tem a função de criar o arquivo de entrada do IMEX a partir da leitura de um arquivo de TEMPLATE e dos parâmetros gerados pelo DAKOTA, e o segundo a função de ler o arquivo de saída do IMEX para obter o valor da produção acumulado ao longo do tempo e calcular a função-objetivo.

Nas tabelas abaixo podem ser visualizadas as descrições e os parâmetros de entrada dos scripts de pré-processamento e pós-processamento:

Tabela 8 - Descrição e parâmetros de entrada do script de pré-processamento.

Scripts	Descrição	Parâmetro de Entrada
analysisDriver.m	Programa principal que chama os outros scripts	
readDakotaParam.m	Lê arquivo de parâmetro do DAKOTA, seleciona e grava o nome e o valor da variável em um vetor	paramFile - Nome do arquivo de parâmetro do DAKOTA
processFilesN.m	Copia o arquivo de TEMPLATE para um arquivo de entrada do IMEX, substituindo o valor da variável contido no parâmetro de entrada Tags pela variável indicada no TEMPLATE	TemplateFile – Nome do arquivo de TEMPLATE Output – Nome do arquivo de saída do IMEX Tags – Vetor com o nome e valor da variável Marker – Delimitador de variável

Tabela 9 – Descrição e parâmetros de entrada do script de pós-processamento.

Scripts	Descrição	Parâmetro de Entrada
posProcessadorImex.m	Recupera o tempo e a produção acumulada do arquivo de saída do IMEX, que serão utilizados no cálculo do ajuste de histórico	dakotaResponseFile – Nome do arquivo que contém os dados do tempo e da produção calculada simOutputFile – Nome do arquivo de saída do IMEX realFile – Nome do arquivo que contém os dados do tempo e da produção observada
cleanup.m	Remove todos os arquivos temporários criados em cada avaliação de função	runDir – Diretório onde a aplicação esta sendo executada imexFile – Nome do arquivo do IMEX

6 Aplicações

Neste capítulo serão apresentados a descrição física e numérica dos modelos de reservatório usados nas aplicações de ajustes de histórico utilizando a metodologia proposta. Dois casos serão estudados, onde o reservatório é representado respectivamente por um campo de permeabilidade com três regiões distintas e um campo de permeabilidade estocástico. A avaliação do comportamento da previsão futura da produção é também apresentada.

6.1 Descrição do Cenário

O cenário aqui proposto visa validar os resultados do procedimento de ajuste de histórico, em simulação numérica de reservatório de petróleo, juntamente com técnicas de otimização por aproximação sequencial.

Dois modelos de reservatório foram utilizados. No primeiro, o valor da permeabilidade foi definido em três regiões distintas, apresentando características mais simples com objetivo de estudar e avaliar as técnicas e os resultados gerados durante o processo de ajuste de histórico de produção. O segundo, com características mais complexas, envolve um campo de permeabilidades estocástico, caracterizando a incerteza numa das variáveis de entrada no modelo.

As técnicas para estudos do processo de ajuste de histórico de produção apresentadas foram aplicadas no caso de um reservatório de petróleo com injeção de água (waterflooding - WF). A injeção de água é um método de recuperação secundária capaz de garantir manutenção da pressão do reservatório em níveis desejáveis, além de propiciar o deslocamento dos hidrocarbonetos dos poros para os poços produtores.

A informação retirada do arquivo de resultado do simulador (saída) para calcular o ajuste de histórico é a produção acumulada nas condições de superfície

(óleo, água e gás) do campo de petróleo. Diferentes situações foram aplicadas no modelo de reservatório, nas quais as restrições no corte de água (Water Cut) e/ou pressões de fundo de poço (BHP) estiveram ativadas ou não nos poços produtores. Foram selecionadas quatro situações, denominadas aqui como “Casos C1 à C4” e detalhadas na tabela abaixo.

Tabela 10 – Restrição no poço.

Casos	Restrição no poço
C1	Sem restrições de BHP e WCUT
C2	Com Restrição apenas no BHP
C3	Com Restrição apenas no WCUT
C4	Com Restrição no BHP e WCUT

No caso C1, não houve qualquer restrição para os poços produtores. No caso C2, os poços produtores foram configurados para restrição de BHP mínimo (ajustado para 180 Kgf/cm²). No caso C3, os poços produtores foram configurados para restrição de Water Cut máximo (ajustado para 95%). No caso C4 foram consideradas as restrições tanto para BHP como para WCUT, ou seja, combinação dos casos C2 e C3 respectivamente.

Para construção do modelo aproximado, através do modelo de regressão polinomial, foi necessário gerar um conjunto de pontos (amostra) pela técnica de amostragem LHS. A quantidade de pontos da amostra variou de acordo com o número de variáveis de projeto.

O parâmetro selecionado para o ajuste foi o valor de permeabilidade, a partir do qual geraram-se dados para análise. Os ajustes realizados foram feitos para a produção acumulada de óleo do campo.

6.2 Casos propostos para estudo

O objetivo principal deste estudo foi tentar identificar as dificuldades reais e potenciais inerentes à aplicação do processo de ajuste de histórico de produção

em simulação numérica de reservatório de petróleo; bem como tentar encontrar o melhor caminho para solucionar os problemas.

Este estudo foi aplicado a dois ajustes de características distintas. Cada um dos casos possui particularidades definidas no que se refere à complexidade do modelo de reservatório.

6.2.1 Ajuste A

O primeiro ajuste apresentou geometria simples e características fáceis de controlar. O valor da permeabilidade foi definido em três regiões do modelo, conforme a Figura 14. A região próxima ao poço injetor (I-1), ilustrada pela cor verde, possui valores da permeabilidade igual ao valor de base, ou seja, 100 mD. A outra região, próxima ao poço produtor P-1, ilustrada pela cor azul, possui permeabilidade inferior ao valor de base. A região próxima ao produtor P-2, ilustrada pela cor vermelha, possui valores superiores à permeabilidade base. A razão entre a permeabilidade da região do poço P-2 e a do poço P-1 representa o contraste de permeabilidade. Trabalhou-se com um contraste de permeabilidade de 3:1, a partir do uso dos valores de permeabilidade de 50mD próximo ao poço P-1, e 150mD na região do poço P-2.

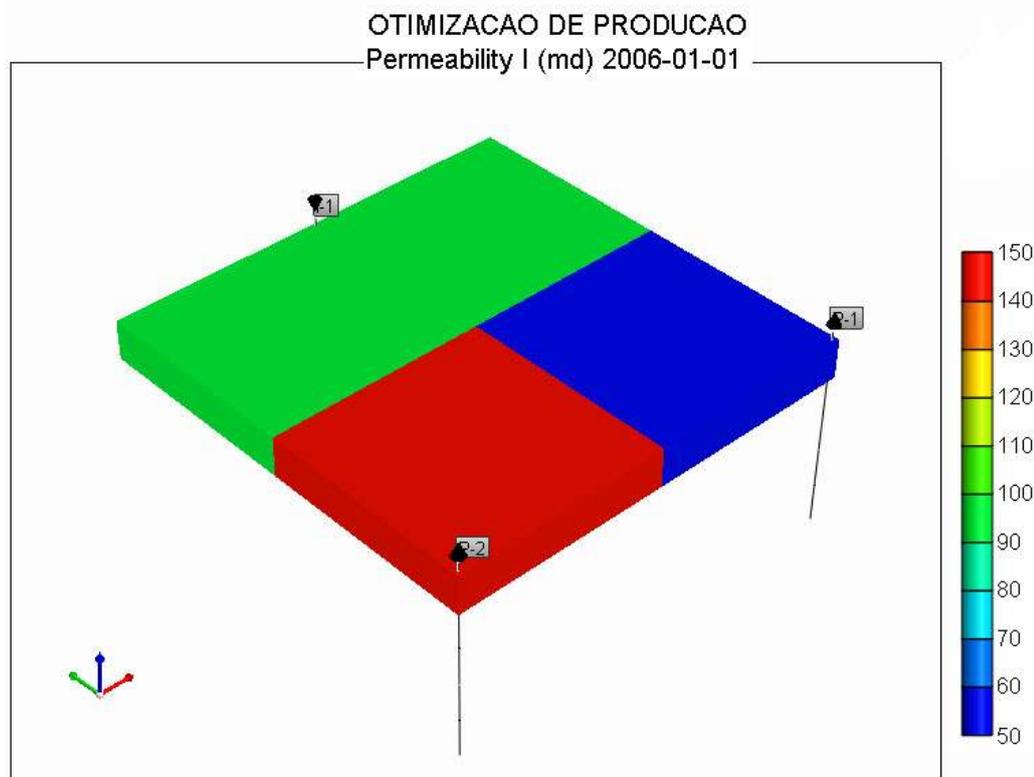


Figura 14 - Regiões de Permeabilidade Horizontal.

O modelo utilizado é baseado no trabalho de [26], possui 51x51x1 células e apresenta as propriedades resumidas na Tabela 11.

Tabela 11 - Resumo das características do modelo base.

Propriedade	Dados
Malha de Simulação	51(510m)x51(510m)x1(4m)
Porosidade	30%
Permeabilidade horizontal média (K_h)	100 mD
Permeabilidade vertical (K_v)	10% de K_h
Compressibilidade da Rocha @ 200 kgf/cm ²	$5 \cdot 10^{-5}$ (kgf/cm ²) ⁻¹
Contatos entre Fluidos	Sem contatos WOC e GOC
Pressão de Saturação (P_{sat})	273 kgf/cm ²
Viscosidade @ T_{res} , P_{sat}	0.97 cP
Razão Gás-Óleo de Formação ($RGOF$)	115.5 m ³ /m ³ std

A geração do modelo de reservatório foi baseada nas informações mostradas na Tabela 11. Este possui um poço injetor de água (I-1) e dois poços produtores de óleo (P-1 e P-2), que são poços verticais completados em uma única camada do modelo.

Os poços produtores são restringidos por uma vazão máxima de líquido de 30m³/dia e o poço injetor é controlado apenas pela vazão máxima de água injetada, definida em 44m³/dia. Esse valor foi adotado buscando a manutenção da pressão média do reservatório. As vazões dos poços são apresentadas a cada passo de tempo. O intervalo de produção pode variar de acordo com a restrição de poço imposta.

A aplicação possui um tempo total de produção de 16 anos (01/01/2006 a 01/12/2021). Neste exemplo, as vazões dos dois poços produtores de óleo (P-1 e P-2) foram ajustadas ambas em 20m³/dia no período de produção. O limite à vazão de líquido foi fixado em 40m³/dia, refletindo a máxima vazão diária de produção capaz de ser tratada pela unidade.

Nesta primeira etapa a variável permeabilidade horizontal (K_h) adotou o valor base de 100mD .

O modelo de simulação base foi utilizado para geração dos dados da produção observada. Durante a simulação e otimização, com a alteração da variável do projeto, foram gerados os dados da produção calculada. Com o resultado do histórico de produção observado e calculado é calculada a função-objetivo do nosso problema utilizando a Equação (4.1).

Após a simulação do modelo base foram geradas as curvas de produção acumulada do óleo observada (modelo base) no decorrer do tempo e em relação aos quatro tipos de restrições de poços apresentados na Tabela 10. Tais produções estão ilustradas nas Figuras 15 a 18.

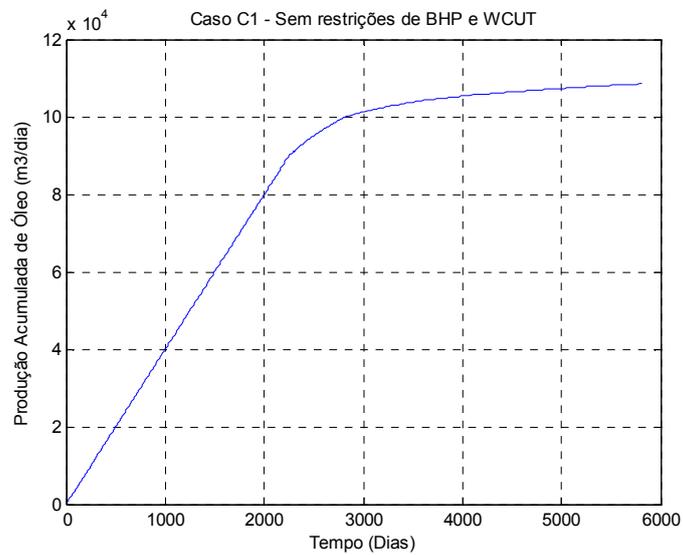


Figura 15 - Curva de Produção Acumulada de Óleo Observada – Caso C1.

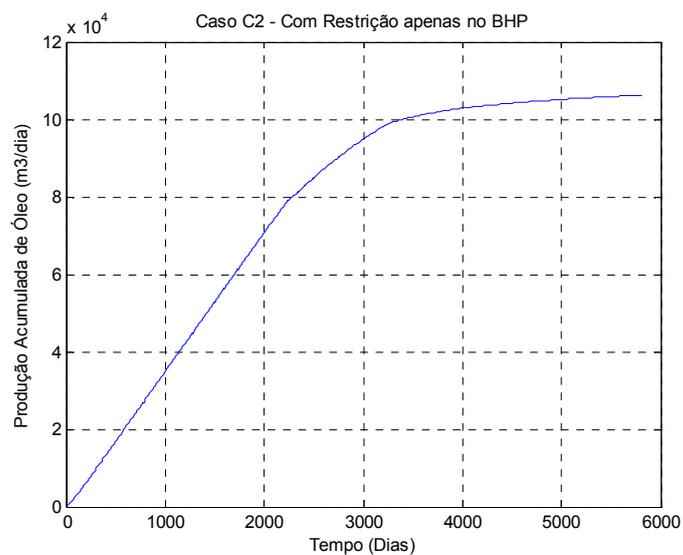


Figura 16 - Curva de Produção Acumulada de Óleo Observada – Caso C2.

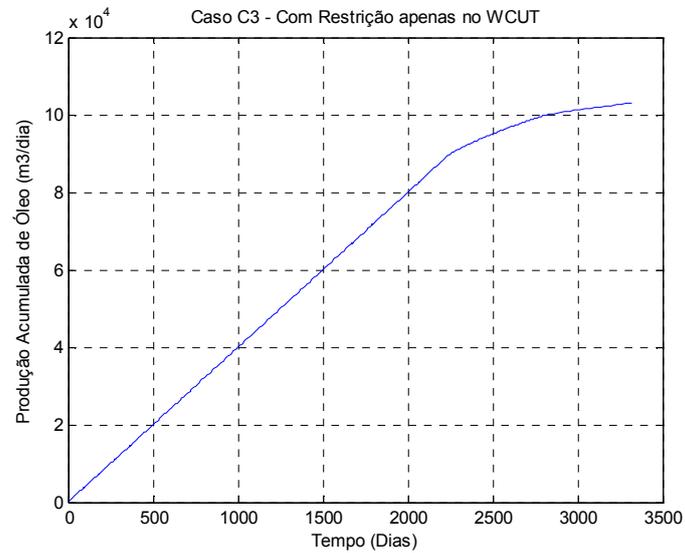


Figura 17 - Curva de Produção Acumulada de Óleo Observada – Caso C3.

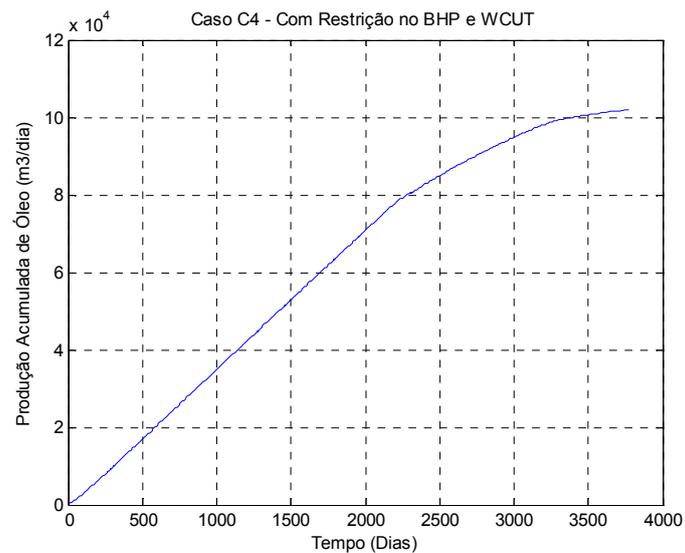


Figura 18 - Curva de Produção Acumulada de Óleo Observada – Caso C4.

Esses dados servirão como base de comparação entre os próximos casos propostos deste ajuste, estabelecendo condições para avaliar o resultado final.

6.2.1.1 Ajuste A - Caso 1: Uma variável de projeto; Contraste de permeabilidade 1:3

Este primeiro caso foi representado por uma variável de projeto (permeabilidade horizontal - K_h).

Para iniciar o processo de ajuste, foi realizado um estudo paramétrico com o intuito de assegurar que a produção inicial iria partir de um ponto diferente da produção observado e, posteriormente, avaliar a sensibilidade do modelo a partir da variação da permeabilidade. A resposta analisada é a produção acumulada do óleo. Como resultado deste estudo as seguintes condições foram aplicadas:

- Permeabilidade inicial = $k_{h_{inicial}} = 25$ mD
- Restrições de limite = $16 \leq k_h \leq 200$ mD ($k_{h_{Base}} = 100$ mD)

O processo de ajuste de histórico de produção foi obtido através da simulação, juntamente com um método de otimização baseada em aproximação sequencial (SAO), cuja meta foi reduzir a função-objetivo. Abaixo são apresentados os principais controles com seus respectivos valores do SAO utilizado no DAKOTA:

```

max_iterations = 50
convergence_tolerance = 1e-3
soft_convergence_limit = 2
trust_region
  initial_size = 0.10
  minimum_size = 1.0e-3
  contract_threshold = 0.25
  expand_threshold = 0.75
  contraction_factor = 0.50
  expansion_factor = 1.50

```

A iteração SAO, a permeabilidade horizontal (K_h) e a função-objetivo (F_o) gerados durante a otimização dos casos C1 à C4 estão apresentados respectivamente nas Tabelas 12 a 15.

Tabela 12 - Resultado da Otimização- C1.

Caso C1		
Iteração SAO	K_h	F_o
1	25	15.828
11	99.6675737	0.0229062

Tabela 13 - Resultado da Otimização- C2.

Caso C2		
Iteração SAO	K_h	F_o
1	25	40.2334
18	100.0046106	0.0021255

Tabela 14 - Resultado da Otimização- C3.

Caso C3		
Iteração SAO	K_h	F_o
1	25	19.8729
13	99.94335353	0.00437011

Tabela 15 - Resultado da Otimização- C4.

Caso C4		
Iteração SAO	K_h	F_o
1	25	48.6368
13	99.8098551	0.0429445

O caso C2 (com restrição apenas no BHP) apresentou o menor valor da função-objetivo, que em contrapartida obteve o maior número de iterações SAO; porém o caso C1 (sem restrições de BHP e WCUT) obteve o menor número de iterações SAO, atingindo um bom ajuste. No entanto, concluímos que podemos utilizar o modelo numérico deste caso para obtenção de uma previsão do comportamento do reservatório.

Nas figuras abaixo estão apresentados os gráficos das curvas de produção acumulada do óleo observada, inicial e calculada no decorrer do tempo, em relação aos quatro tipos de restrições de poços apresentados na Tabela 10.

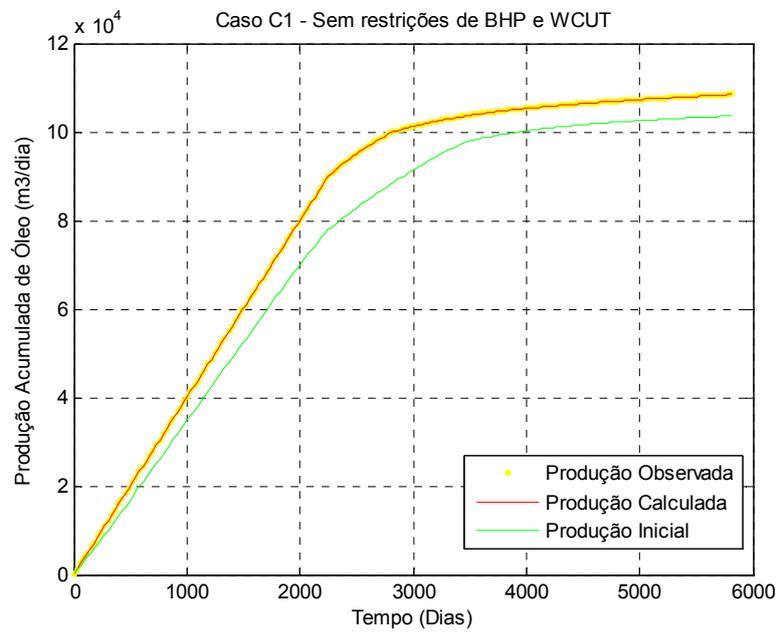


Figura 19 - Ajuste da Produção de Óleo – Caso C1.

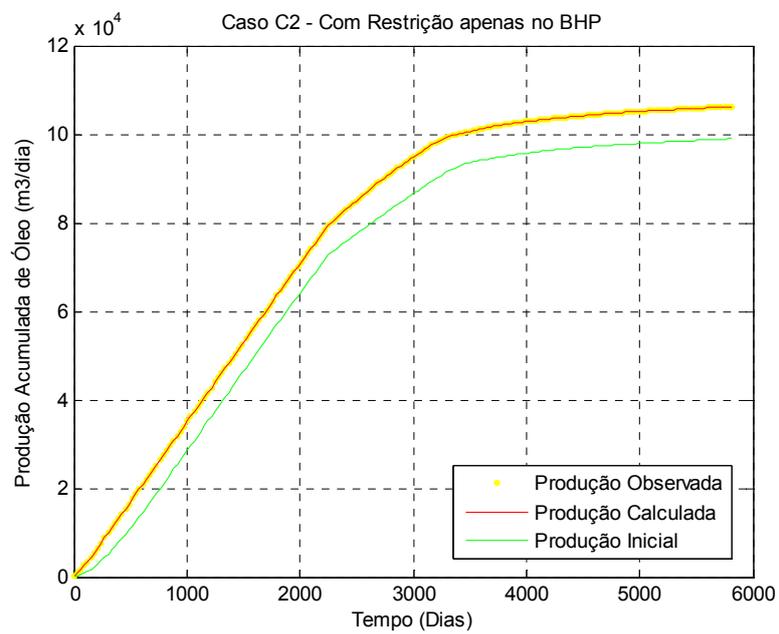


Figura 20 - Ajuste da Produção de Óleo – Caso C2.

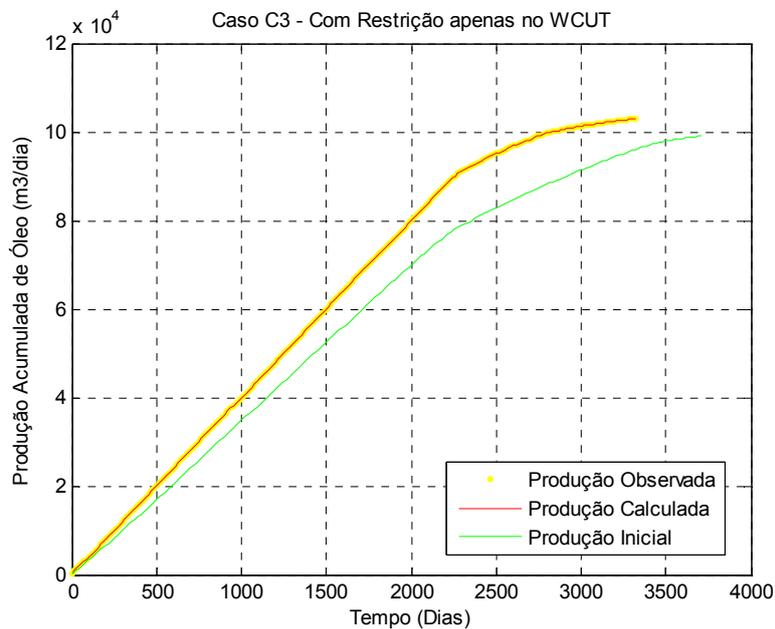


Figura 21 - Ajuste da Produção de Óleo – Caso C3.

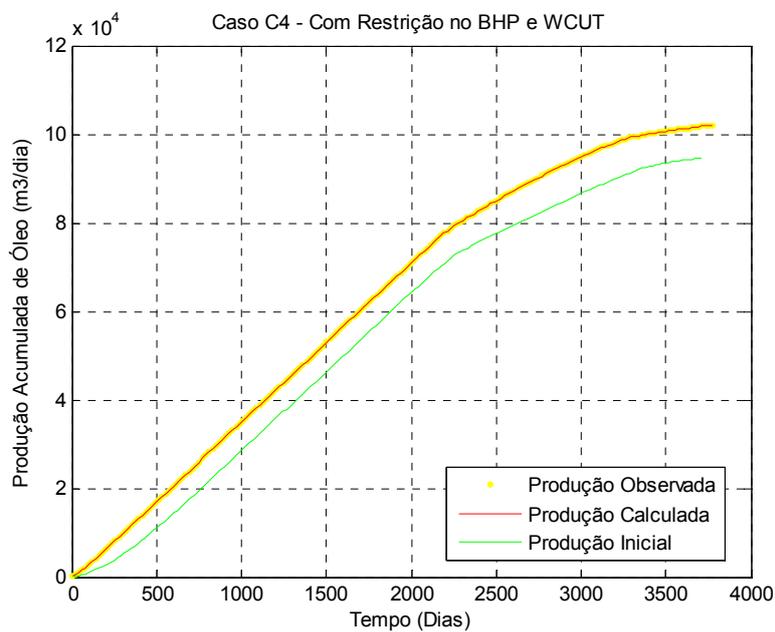


Figura 22 - Ajuste da Produção de Óleo – Caso C4.

Os quatro tipos de restrições de poços mostraram-se bastante sensíveis ao resultado da otimização, ou seja, houve a redução da função-objetivo e, como

pode ser visualizada, a curva final (produção calculada) apresentou-se bastante próxima dos dados observados.

6.2.1.2 Ajuste A - Caso 2: Três variáveis de projeto

O segundo caso é uma extensão do primeiro, com a inclusão de dois parâmetros adicionais. Neste ajuste cada variável de projeto foi representada por uma região do modelo, conforme mostrado na Figura 14; ou seja, além do primeiro parâmetro, correspondente à região próxima ao poço injetor I-1, são considerados também um parâmetro representado pela região próxima ao produtor P-2 e o outro pela região próxima ao poço produto P-1.

Neste caso, o contraste de permeabilidade não assumiu mais um percentual de 150% e 50% da permeabilidade horizontal (K_h) como no Ajuste A - Caso 1. Os valores foram atribuídos a dois parâmetros que foram modificados dinamicamente durante o processo de otimização.

Como no Ajuste A, para dar início ao processo de ajuste foi realizado um estudo paramétrico com o intuito de assegurar que a produção inicial iria partir de um ponto diferente da produção observado.

O ajuste parte inicialmente de um modelo observado. Os valores das permeabilidades usados no caso base, no ponto inicial bem como os seus limites utilizados no procedimento de otimização, estão indicados abaixo:

$$\rightarrow \text{Permeabilidade base} = k_{h1_{Base}} = 100 \text{ mD}$$

$$k_{h2_{Base}} = 150 \text{ mD}$$

$$k_{h3_{Base}} = 50 \text{ mD}$$

$$\rightarrow \text{Permeabilidade inicial} = k_{h1_{Inicial}} = 50 \text{ mD}$$

$$k_{h2_{Inicial}} = 75 \text{ mD}$$

$$k_{h3_{inicial}} = 25 \text{ mD}$$

$$\rightarrow \text{Restrições de limite} = 16 \leq k_{h1} \leq 150 \text{ mD}$$

$$20 \leq k_{h2} \leq 200 \text{ mD}$$

$$10 \leq k_{h3} \leq 100 \text{ mD}$$

Os resultados da otimização para este exemplo estão fornecidos nas Tabelas 16 a 19 respectivamente para cada condição de restrição de poço indicada na Tabela 10.

Tabela 16 - Resultado da Otimização – C1.

Caso C1				
Iteração SAO	K_{h1}	K_{h2}	K_{h3}	F_o
1	50	75	25	4.25297
7	84.3375	107.7791808	58.54182322	0.384337

Tabela 17 – Resultado da Otimização – C2.

Caso C2				
Iteração SAO	K_{h1}	K_{h2}	K_{h3}	F_o
1	50	75	25	15.6682
11	95.21158769	155.1360883	49.04427832	0.308472

Tabela 18 – Resultado da Otimização – C3.

Caso C3				
Iteração SAO	K_{h1}	K_{h2}	K_{h3}	F_o
1	50	75	25	5.45307
16	66.08401248	150.1020359	52.2184962	0.191019

Tabela 19 – Resultado da Otimização – C4.

Caso C4				
Iteração SAO	K_{h1}	K_{h2}	K_{h3}	F_o
1	50	75	25	19.2074
11	91.80478821	148.55824	50.3874516	0.276534

O caso C3 (com restrição apenas no WCUT) apresentou o menor valor da função-objetivo, mas, em contrapartida, obteve o maior número de iterações SAO; porém o caso C1 (sem restrições de BHP e WCUT) obteve o menor número de iterações SAO, atingindo um bom ajuste. Entretanto, concluímos que podemos

utilizar o modelo numérico deste caso para obtenção de uma previsão do comportamento do reservatório.

Nas figuras a seguir estão apresentados os gráficos das curvas de produção acumulada do óleo nas diferentes situações: observada, inicial e calculada no decorrer do tempo para cada um dos casos apresentados na Tabela 10.

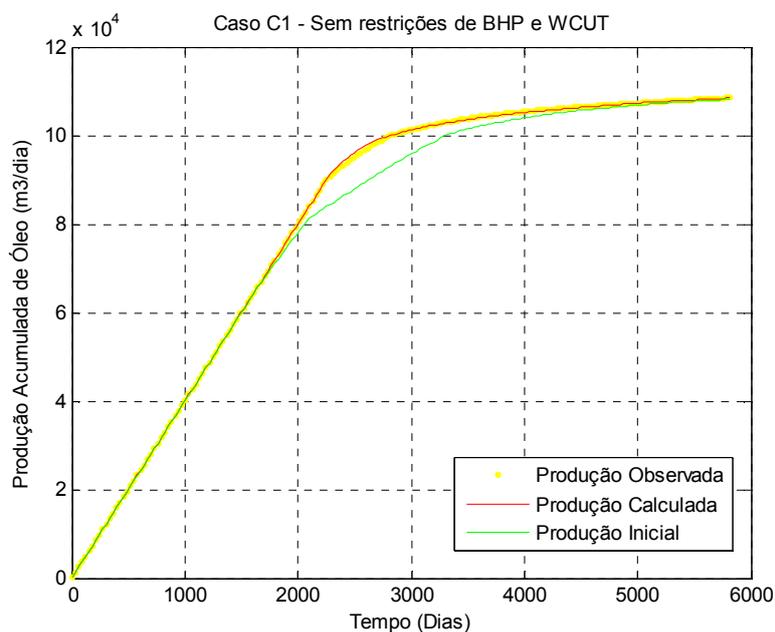


Figura 23 - Ajuste da Produção de Óleo – Caso C1.

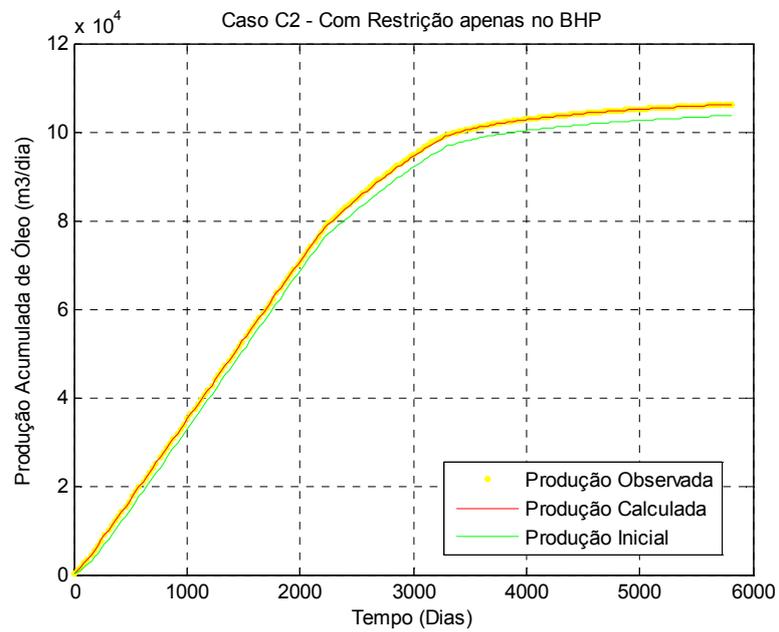


Figura 24 - Ajuste da Produção de Óleo – Caso C2.

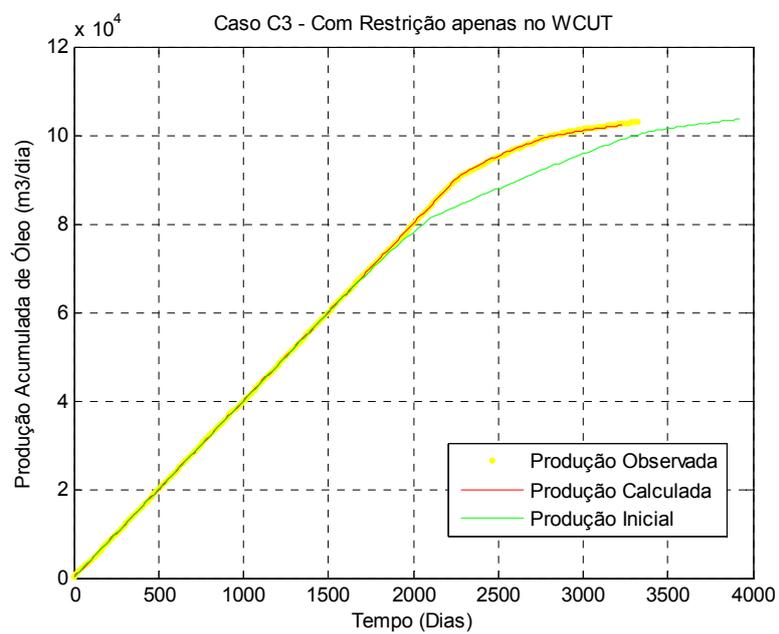


Figura 25 - Ajuste da Produção de Óleo – Caso C3.

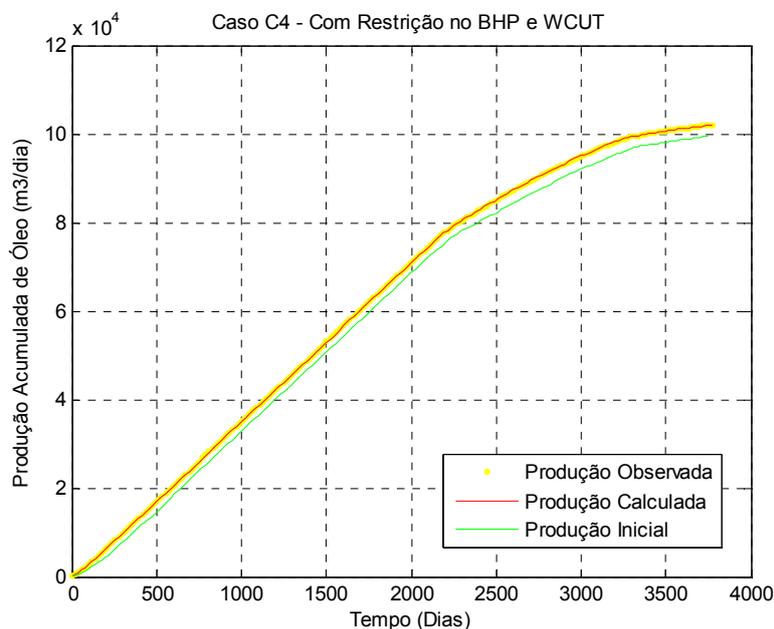


Figura 26 - Ajuste da Produção de Óleo – Caso C4.

Os quatro tipos de restrições de poços mostraram-se bastante sensíveis ao resultado da otimização, ou seja, houve a redução da função-objetivo e, como pode ser visualizado, a curva final (produção calculada) apresentou-se bastante próxima dos dados observados.

6.2.1.3 Ajuste A - Caso 3: Uma variável de projeto; Permeabilidade constante no reservatório

O terceiro caso também é uma extensão do primeiro, com a diferença que o valor da permeabilidade no modelo do reservatório durante a produção simulada foi considerado constante em todo o campo de petróleo. Entretanto, a produção observada é a mesma dos casos anteriores onde existe um contraste de permeabilidade 1:3, com os valores já especificados na descrição do exemplo no início da seção 6.2.1 e também na seção 6.2.1.2.

O valor inicial da variável de projeto bem como os seus limites utilizados no procedimento de otimização está abaixo indicado:

→ Permeabilidade inicial = $k_{h_{inicial}} = 25$ mD

→ Restrições de limite = $16 \leq k_h \leq 200$ mD ($k_{h_{base}} = 100$ mD)

Os resultados da otimização para todas as condições de restrição de poço (casos C1 à C4) estão apresentados nas Tabelas 20 a 23 respectivamente.

Tabela 20 - Resultado da Otimização- C1.

Caso C1		
Iteração SAO	K_h	F_o
1	25	13.4646
13	76.94136024	0.589944

Tabela 21 - Resultado da Otimização- C2.

Caso C2		
Iteração SAO	K_h	F_o
1	25	39.19
9	97.42763311	2.26126

Tabela 22 - Resultado da Otimização- C3.

Caso C3		
Iteração SAO	K_h	F_o
1	25	17.0637
9	71.8063238	0.60334

Tabela 23 - Resultado da Otimização- C4.

Caso C4		
Iteração SAO	K_h	F_o
1	25	47.3676
8	97.50770404	2.76959

De acordo com os resultados, observa-se que, apesar de considerar a permeabilidade constante, a curva de produção calculada continua próxima dos dados observados, ou seja, para este caso “simples” tem-se sempre um bom ajuste de histórico.

Este caso serviu para avaliar o comportamento do modelo de simulação decorrente desta situação. Entretanto, o Ajuste A baseou-se num problema sim-

ples, que teve como principal objetivo estudar e avaliar as técnicas e os resultados gerados durante o processo de ajuste de histórico de produção. A partir deste ajuste outras situações poderão ser implementadas, desde que não haja alteração do contexto da aplicação.

Nas figuras a seguir estão apresentados os gráficos entre a curva de produção acumulada do óleo observada e calculada no decorrer do tempo, em relação aos quatros tipos de restrições de poços apresentados na Tabela 10.

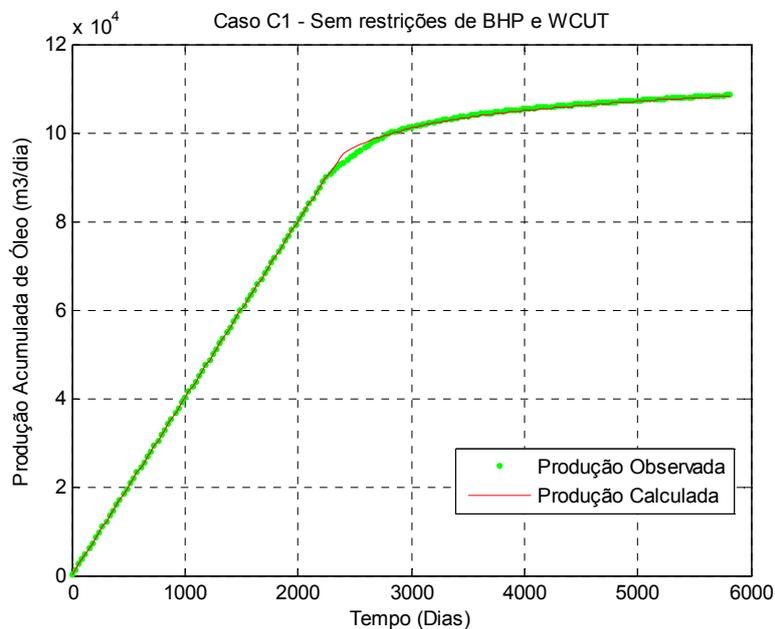


Figura 27 - Ajuste da Produção de Óleo – Caso C1.

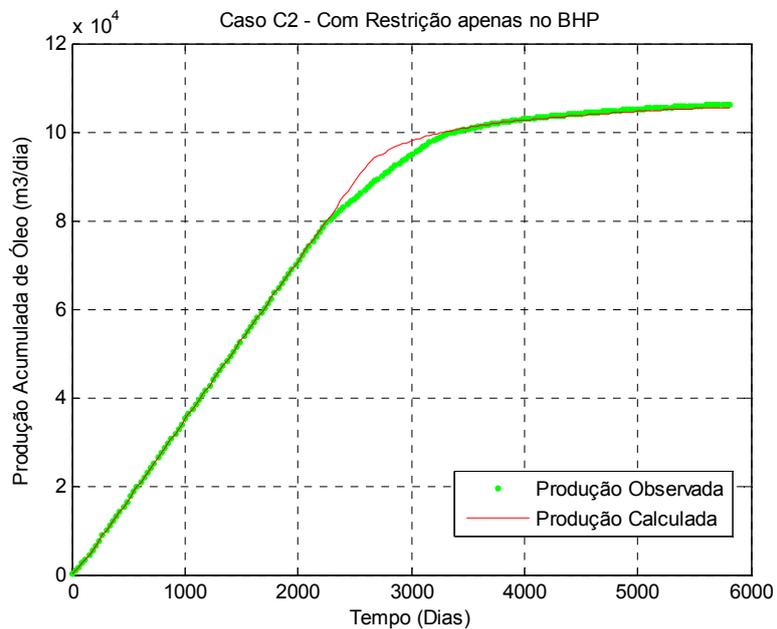


Figura 28 - Ajuste da Produção de Óleo – Caso C2.

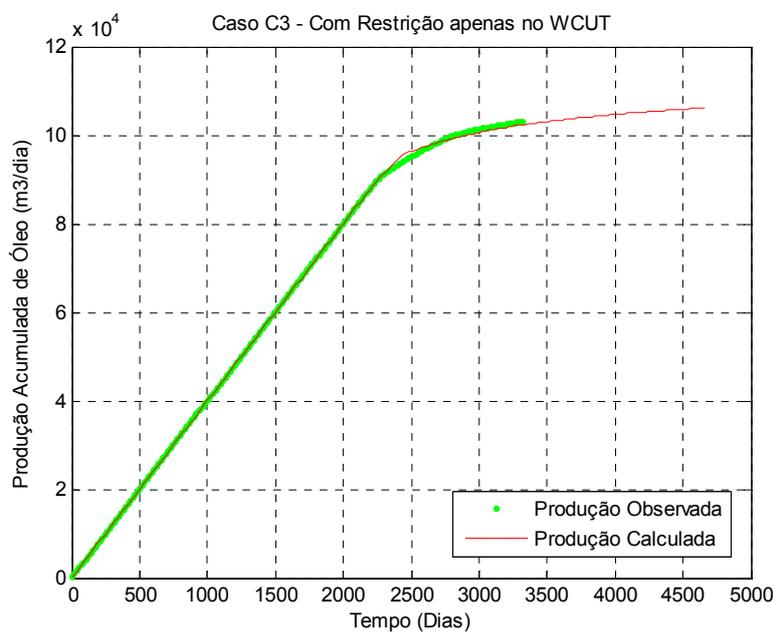


Figura 29 - Ajuste da Produção de Óleo – Caso C3.

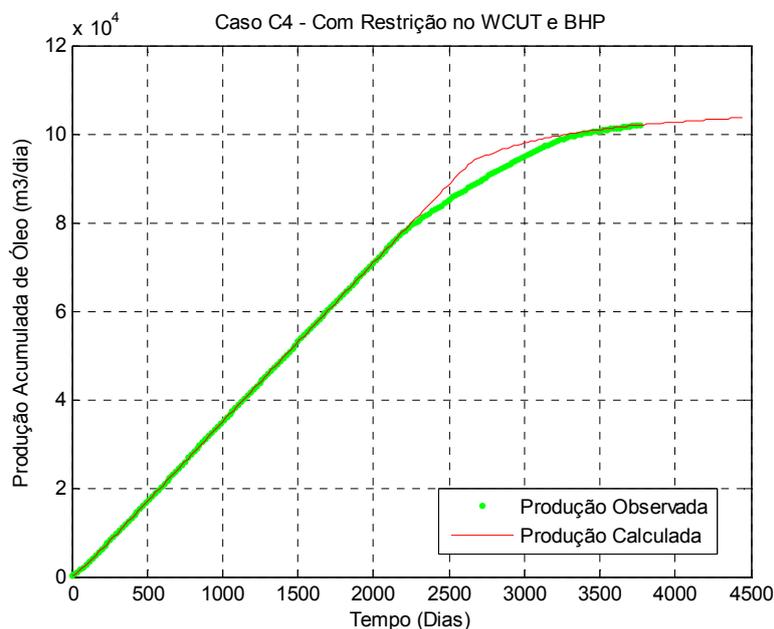


Figura 30 - Ajuste da Produção de Óleo – Caso C4.

Como pode ser verificado, pequenas divergências ocorreram. As maiores diferenças ocorreram para o caso C4, seguido do caso C2.

6.2.2 Ajuste B

Este ajuste foi baseado no trabalho de [20], possui um modelo de reservatório com característica mais complexa. O seu objetivo é fazer um ajuste de histórico considerando o campo de permeabilidade para o reservatório anteriormente descrito como um campo estocástico, caracterizando a incerteza numa das variáveis de entrada no modelo.

Neste trabalho o campo estocástico será representado através de uma expansão de Karhunen-Loeve, que é uma expansão em termos dos autovalores e autovetores da matriz de covariância espacial do campo, e de variáveis aleatórias normais padrão. Esta técnica permite representar campos aleatórios estacionários

[Os resultados desta seção foram trabalhados em conjunto com o aluno Dásio Lira]

e os fracamente estacionários com o conhecimento explícito de funções de covariância. Sendo assim, um campo aleatório pode ser representado como uma série, envolvendo um conjunto de funções determinísticas com seus respectivos coeficientes aleatórios, como apresentado por [35].

Quando um campo de permeabilidade é considerado como um campo estocástico, existem infinitas realizações igualmente possíveis para as propriedades petrofísicas deste campo. Neste trabalho as realizações foram criadas a partir de uma função de covariância conhecida, conforme a equação abaixo [20]:

$$\text{cov}(x, y) = \sigma_E e^{-\frac{(|x_1 - y_1|)}{b_1} - \frac{(|x_2 - y_2|)}{b_2}} \quad (6.1)$$

onde (x_1, x_2) e (y_1, y_2) são as coordenadas dos pontos x e y , b_1 e b_2 são comprimentos de correlação e σ_E é o desvio padrão.

Considerando \mathbf{y}_k um conjunto de realizações discretas centradas (média zero) condicionadas ou não condicionadas de um campo estocástico, com $k = 1, \dots, N_r$ ($\mathbf{y}_k \in R^{N_c}$), a matriz de covariância das realizações pode ser calculada com a seguinte expressão, de acordo com [37]:

$$\mathbf{C} = \frac{1}{N_r} \sum_{j=1}^{N_r} \mathbf{y}_j \mathbf{y}_j^T \quad (6.2)$$

onde N_r é o número de realizações e N_c o número de células no reservatório.

A expansão de Karhunen-Loeve discreta, usada para gerar novas realizações com a matriz de covariância \mathbf{C} conhecida é apresentada em [35] tal como segue:

$$\mathbf{y} = \mathbf{E} \mathbf{\Lambda}^{1/2} \boldsymbol{\xi} \quad (6.3)$$

onde \mathbf{E} é a matriz dos auto-vetores da matriz de covariância \mathbf{C} , $\mathbf{\Lambda}$ é a matriz diagonal de autovalores de \mathbf{C} , e ξ é um vetor de variáveis aleatórias não correlacionadas.

A matriz \mathbf{C} é do tamanho $N_c \times N_c$. O tamanho máximo de \mathbf{E} como também de $\mathbf{\Lambda}$ é $N_c \times N_c$, sendo o vetor ξ de tamanho $N_c \times 1$.

A Equação (6.3) permite descrever o campo estocástico em termos de um conjunto finito de variáveis aleatórias normais padrão (ξ). Estas variáveis podem então ser empregadas como variáveis do projeto em um procedimento de otimização. É interessante observar que, usualmente, a magnitude dos autovalores da matriz de covariância cai muito rapidamente e poucos termos do somatório implícito na Equação (6.3) são necessários para uma representação adequada do campo [35].

Neste trabalho, foi empregada a técnica de matriz núcleo para redução do esforço computacional no cálculo dos autovalores e auto-vetores da matriz de covariância [35][37].

O Ajuste B é derivado do Ajuste A, com a diferença que no modelo de reservatório temos um valor de permeabilidade para cada célula, ou seja, o campo de permeabilidade será considerado como um campo estocástico. Foi considerada restrição apenas no BHP em cada poço.

No modelo base o campo de permeabilidades foi escolhido como uma das realizações aleatórias geradas a partir da função de covariância dada na Equação (6.1). O histórico de produção gerado pela simulação computacional com este campo de permeabilidade será usado como o dado observado para o ajuste de histórico.

Abaixo é ilustrado o campo de permeabilidade base (observado) aleatório:

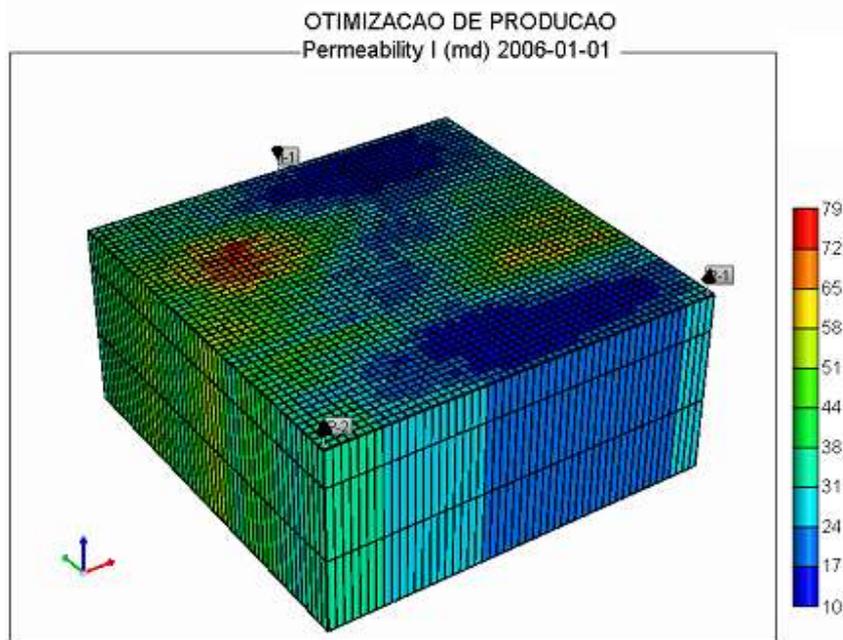


Figura 31 - Campo base.

6.2.2.1 Ajuste B - Caso 1: Uma variável; Permeabilidade constante no reservatório

No primeiro caso foi realizado um ajuste considerando um campo de permeabilidade constante em todo campo de petróleo. Este ajuste foi representado por uma variável de projeto.

O valor inicial e os seus limites utilizados no procedimento de otimização são abaixo indicados:

- Permeabilidade inicial = $k_{hInicial} = 10$ mD
- Restrições de limite = $10 \leq k_h \leq 80$ mD $k_{hBase} = 100$ mD

Na Figura 32 é ilustrado o campo de permeabilidade inicial:

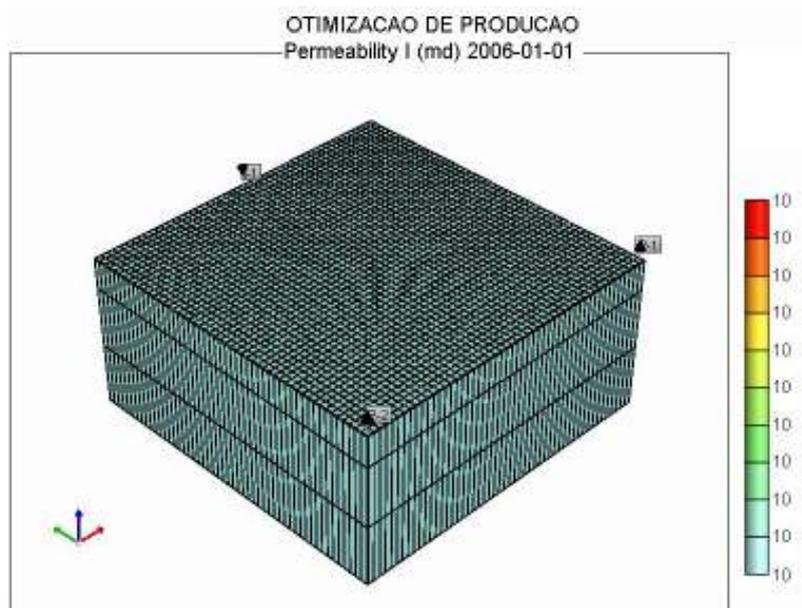


Figura 32 - Campo de permeabilidade constante inicial.

Os resultados da otimização estão apresentados na Tabela 24.

Tabela 24 - Resultado da Otimização.

Iteração SAO	K_h	F_o
1	10	115.448
9	24.97716787	7.25348

Com o resultado da otimização foi gerado o gráfico da curva de produção acumulada do óleo calculada no decorrer do tempo tal como indicado na Figura 33. Nesta figura, esta também plotado a produção acumulada do óleo para as situações observada e inicial.

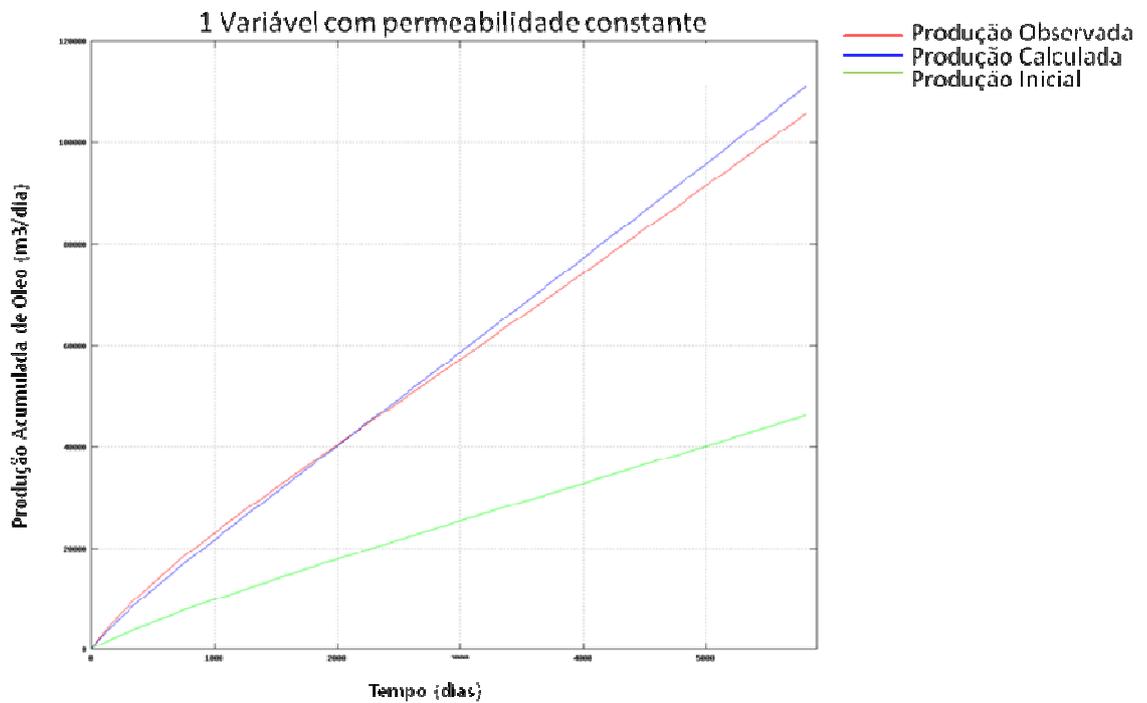


Figura 33 - Ajuste da Produção de Óleo.

De acordo com os resultados apresentados na Tabela 24 e Figura 33, observa-se que a curva de produção inicial partiu de ponto distante da produção observada e, durante a otimização aproximou-se dos dados observados, como pode ser visto através da redução da função-objetivo. Entretanto, a curva final (produção calculada) apresentou-se com necessidade de um melhor ajuste, pois uma extrapolação no tempo certamente aumentará a diferença entre as produções.

6.2.2.2 Ajuste B - Caso 2: Uma variável de projeto

No segundo caso foi realizado um ajuste de histórico com expansão de Karhunen-Loeve ($K-L$), considerando um campo de permeabilidade como um

campo estocástico. Neste caso o vetor de variáveis aleatórias (coeficiente da expansão $K-L$ do campo estocástico) é a variável de projeto selecionada.

Este ajuste utilizou apenas uma componente principal, assumindo uma variável do ajuste com limite em 8. O valor inicial bem como os limites da variável é:

→ Componente inicial = $\xi_{1_{inicial}} = 0.1$

→ Restrições de limite = $-2 \leq \xi_1 \leq 8$

O resultado da otimização está apresentado na Tabela 25. Na Figura 34 são apresentadas as produções acumuladas de óleo para as três situações: inicial, observada e calculada.

Tabela 25 - Resultado da Otimização.

Iteração SAO	Coeficiente $K-L$	F_o
1	0.1	44.7107
8	5.0734	2.7925

De acordo com o resultado, observa-se que a curva de produção inicial partiu de ponto distante da produção observada e, durante a otimização aproximou-se dos dados observados, e, como consequência, a curva final (produção calculada) apresentou-se com um ajuste satisfatório.

A distribuição das permeabilidades da solução $K-L$ para o coeficiente otimizado é indicada na Figura 35.

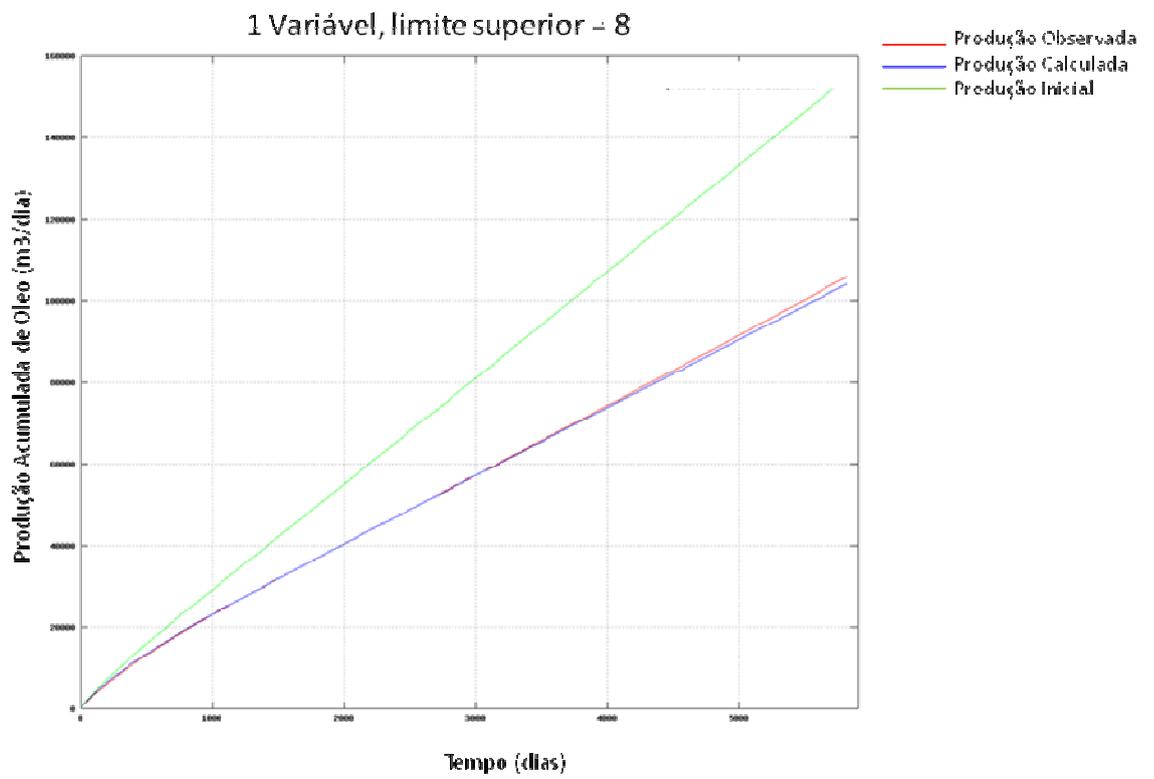


Figura 34 - Ajuste da Produção de Óleo.

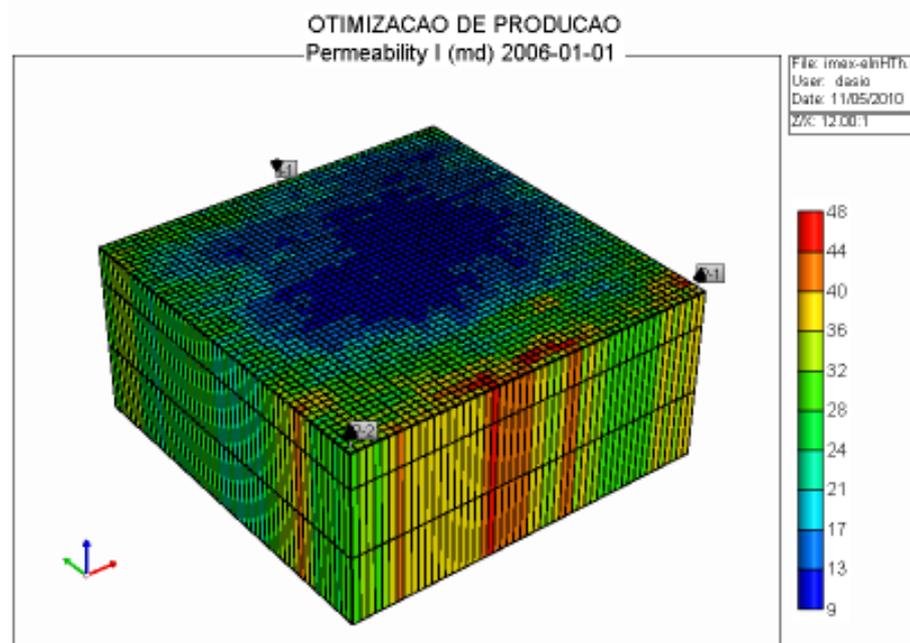


Figura 35 - Campo com ajuste de histórico.

6.2.2.3 Ajuste B - Caso 3: Duas variáveis de projeto

O terceiro caso é uma extensão do anterior, no qual se utilizou dois componentes principais e, portanto duas variáveis de projeto. Os respectivos valores iniciais e limites estão abaixo indicados:

→ Componente inicial = $\xi_{1_{inicial}} = 0.1$

$$\xi_{2_{inicial}} = 0.1$$

→ Restrições de limite = $-2 \leq \xi_1 \leq 8$

$$-2 \leq \xi_2 \leq 8$$

O resultado da otimização está apresentado na Tabela 26. Na Figura 36 são apresentadas as produções acumuladas de óleo para as três situações: inicial, observada e calculada.

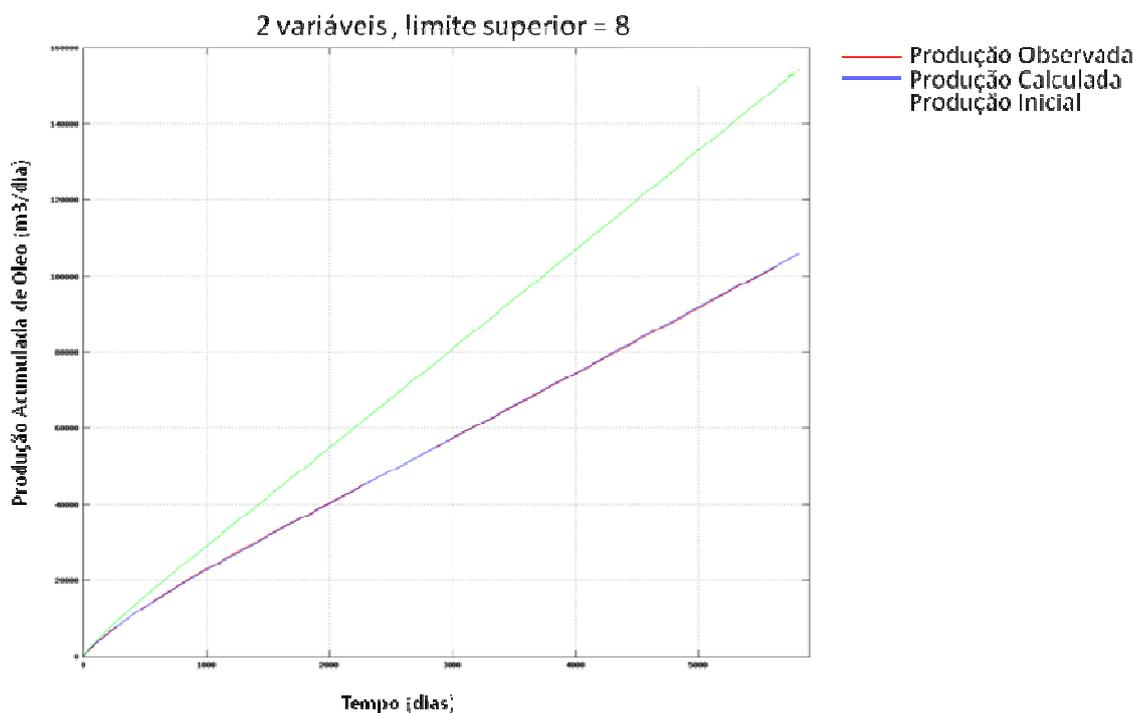
Tabela 26 - Resultado da Otimização.

Iteração SAO	1° Coeficiente K-L	2° Coeficiente K-L	F_o
1	0.1	0.1	44.7107
28	4.5595	1.4213	1.5807

Comparando com o resultado do caso anterior, observa-se que com o aumento de mais uma variável (componente principal) houve uma maior redução da função-objetivo, ou seja, um melhor ajuste dos dados.

Não foi necessário gerar novos casos com o aumento do número de variáveis, visto que o ajuste já foi satisfatório com duas variáveis de projeto.

A distribuição das permeabilidades da solução K-L para o coeficiente otimizado é indicada na Figura 37.

**Figura 36 - Ajuste da Produção de Óleo.**

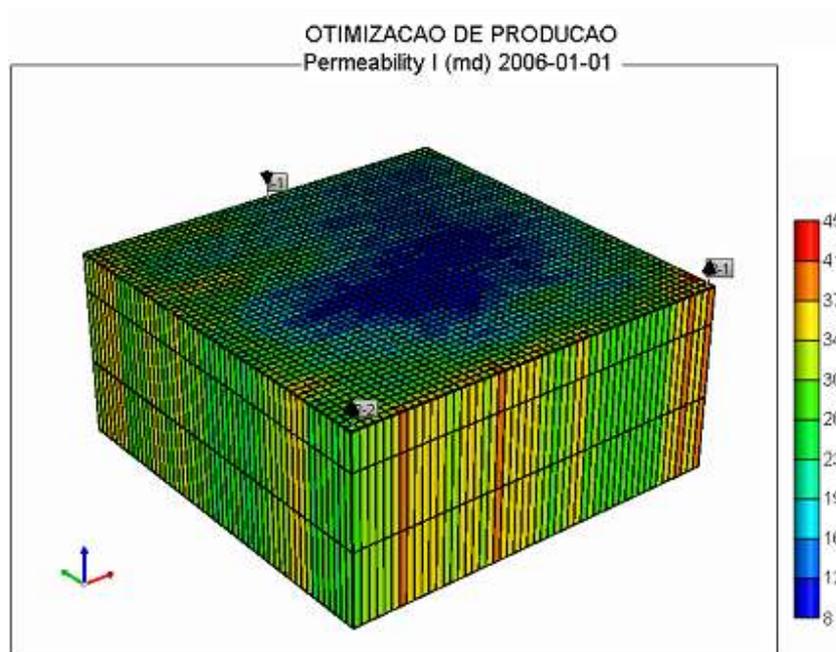


Figura 37 - Campo com ajuste de histórico.

6.3 Previsão Futura

A previsão do comportamento futuro do reservatório é a quarta e última etapa do processo de construção de um modelo de simulação. Uma vez conseguido um bom ajuste de histórico, sua análise fornece melhores subsídios para obter uma previsão de produção para o campo. Assim sendo, o modelo final (ajustado) é utilizado para realizar previsões futuras do reservatório, provendo subsídios para uma exploração mais confiável.

Nesta dissertação, os modelos de reservatório ajustados foram extrapolados por um período adicional de 8 anos, totalizando num período de produção de 24 anos (01/01/2006 a 01/12/2029), para comparar a previsão de produção dos

modelos obtidos no Ajuste A – Caso 2 e no Ajuste B – Caso 3, assim como comparar com os resultados da previsão do modelo de referência (observado).

Primeiramente foi avaliado a previsão do caso 2 do Ajuste A.

A estratégia de recuperação utilizada no processo de previsão é manter as condições de operações dos poços até o final do período de ajuste, por isto só foram consideradas a restrição C1 (sem restrições de BHP e WCUT) e C2 (com restrição apenas no BHP), visto que o período de produção das outras duas restrições (C3 e C4) foram interrompidas antes do período final, pelo encerramento da produção ao encontrar a restrição no WCUT.

A seguir serão apresentados os gráficos com a extrapolação dos modelos com a previsão de produção acumulado do óleo do campo em relação ao Ajuste A – Caso 2 nas restrições de poços C1 e C2 apresentadas na Tabela 10.

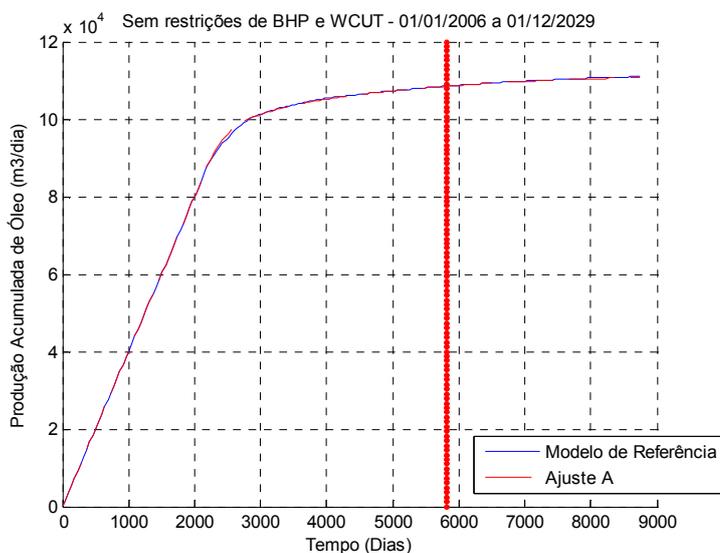


Figura 38 - Previsão futura - Ajuste A – Caso 2 (C1)

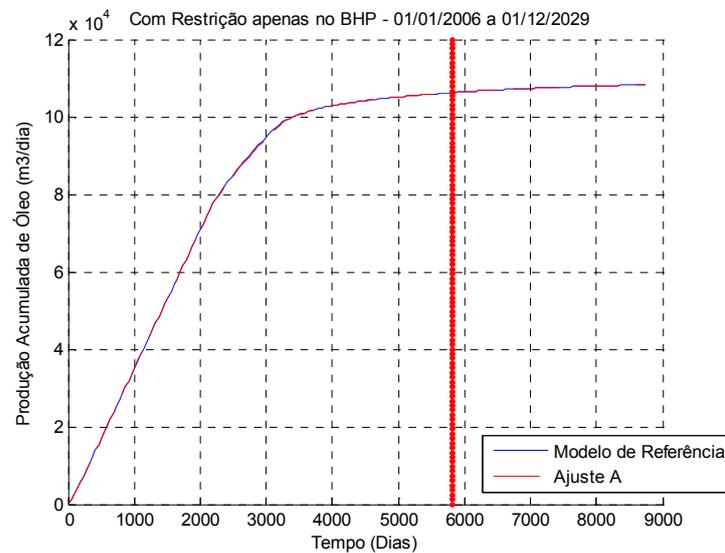


Figura 39 - Previsão futura - Ajuste A – Caso 2 (C2).

Observa-se que a previsão de produção de óleo está bem próxima do modelo de referência nos dois casos, significando que ambos apresentam uma previsão do comportamento futuro confiável.

A seguir será apresentado o gráfico com a extrapolação do modelo com a previsão de produção acumulado do óleo do campo em relação ao Ajuste B – Caso 3.

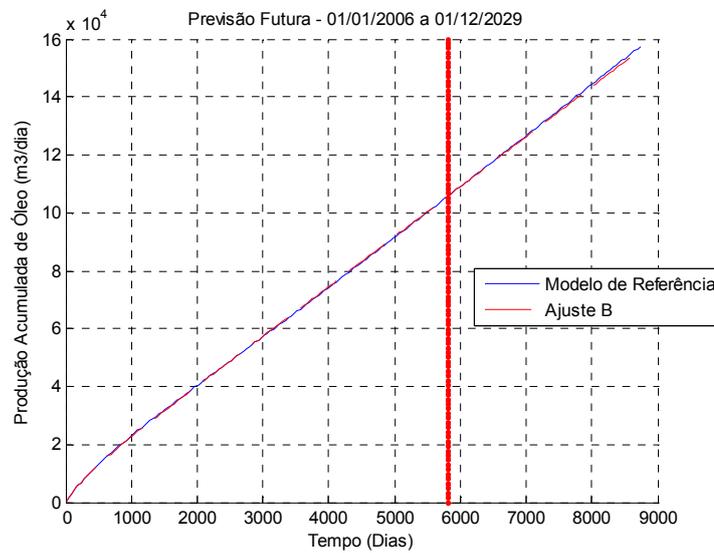


Figura 40 – Previsão futura - Ajuste B – Caso 3.

Observa-se também que neste caso, a previsão de produção de óleo está bem próxima do modelo de referência, significando também uma previsão do comportamento futuro confiável.

7 Conclusão

7.1 Considerações Finais

Visando a diminuição da grande quantidade de simulações numéricas atualmente necessárias para calibrar um modelo numérico, neste trabalho foi apresentada uma estratégia de otimização por aproximação sequencial aplicada a ajuste de histórico, no qual o algoritmo de otimização vai operar em um modelo substituto, de baixo custo computacional, ao invés da simulação do modelo envolvendo a física complexa.

Este trabalho descreveu uma metodologia de integração do ajuste de histórico ao SAO, na qual os principais objetivos são melhorar a confiabilidade da previsão do comportamento de campos de petróleo e reduzir o número de simulações. Isto posto, o estudo realizado para o problema proposto neste trabalho gerou as seguintes conclusões:

1. A utilização do SAO no processo de ajuste de histórico foi aceitável, visto que o ajuste alcançou seu objetivo ao minimizar (aproximar de zero) a função-objetivo, atingindo assim o desempenho ótimo.
2. A metodologia desenvolvida fornece informações que podem auxiliar os profissionais da área de engenharia de reservatórios nas decisões de gerenciamento, como o planejamento de estratégias que podem ser implantadas em campos de petróleo;
3. A implantação do ajuste de histórico pode ser um processo difícil, longo e trabalhoso devido às particularidades e complexidade dos reservatórios de petróleo, por este motivo torna-se difícil definir uma única metodologia. Entretanto, se mostrou ser possível atingir um bom ajuste ao seguir algumas regras, que entre as principais, podemos citar:

- Durante a fase de caracterização do reservatório, antes de construir o modelo de simulação, obter o máximo de informações;
 - Escolha correta dos parâmetros (usando a experiência e análise de sensibilidade);
 - Escolha correta dos limites de variação para todos os parâmetros, evitando rodar o processo sem ganho significativo e sem ultrapassar os limites físicos possíveis;
 - Não variar os parâmetros além dos limites de variação pré-estabelecidos. Se esse procedimento for indispensável, então se deve refazer toda a análise para o parâmetro em questão.
 - Variar primeiro os parâmetros com menor grau de confiabilidade;
 - Rever a estratégia sempre que possível e avaliar constantemente o comportamento da função-objetivo; por exemplo, o avanço da minimização matemática da função-objetivo e a causa desse avanço no ajuste da curva.
4. A metodologia desenvolvida pode ser automatizada com o uso de programas adicionais integrados ao framework DAKOTA e ao simulador IMEX. Uma vez selecionados os parâmetros a serem utilizados, durante o processo de otimização a ferramenta foi capaz de determinar automaticamente uma combinação destas variáveis que proporcione o ajuste da(s) curva(s) selecionada(s). Conseqüentemente, o tempo empregado em estudos de reservatórios pode ser sensivelmente reduzido, já que os recursos disponíveis (homens e máquinas) podem ser utilizados de forma mais eficiente.
 5. Para os quatro tipos de restrições de poços, apresentados na Tabela 10, a função-objetivo apresentou valores próximos do ótimo com diferentes números de iterações SAO, indicando que o bom ajuste pode

ser obtido para diferentes configurações contendo diferentes restrições no poço.

6. Para os diferentes ajustes utilizados, representados por um campo de permeabilidade com três regiões distintas e um campo de permeabilidade estocástico, verificou-se que a função-objetivo se comporta de maneira regular, dando uma maior confiabilidade à ferramenta.
7. A metodologia proposta trabalhou apenas com ajuste de produção, mas acredita-se que todo o procedimento aqui apresentado pode ser estendido para outros tipos de ajustes (função-objetivo).
8. Após o ajuste de histórico foi possível atingir a reprodução de uma boa caracterização do reservatório de petróleo, através de um modelo numérico; e, conseqüentemente, uma boa previsão de produção, auxiliando os gerentes a decidir sobre a viabilidade do projeto.

7.2 Sugestões para Trabalhos Futuros

Muitos pontos podem ser acrescentados e aperfeiçoados de modo a melhorar a qualidade das soluções apresentadas pela metodologia desenvolvida neste trabalho.

A seguir serão indicadas algumas alternativas que poderão ser estudadas em trabalhos futuros.

- Buscar uma melhor caracterização do reservatório a partir de técnicas geoestatística.
- Aplicar as estratégias aproximadas para a otimização multiobjetivo;
- Empregar uma estratégia global de otimização para o problema tratado nesse estudo
- Utilizar a ferramenta desenvolvida neste trabalho em problemas mais complexos da engenharia.

- Considerar as incertezas no processo de otimização.

8 Referências

1. AFONSO, SILVANA M. B.; HOROWITZ, B.; SILVA, M. F. *Application of approximation based strategies for structural design optimization*. Computers and Structures Journal, 2008.
2. AFONSO, SILVANA M. B.; HOROWITZ, BERNARDO; SILVA, MARCELO FERREIRA DA; SIQUEIRA, GILHENDRIK COSTA DE. *Utilização de metamodelos para projeto ótimo de estruturas*. In: CONEM2006- IV Congresso Nacional de Engenharia Mecânica, 2006, Recife.
3. ALBUQUERQUE, THIAGO M. MUNIZ. *Análise e otimização de problemas térmicos e estruturais bidimensionais através do método da base reduzida*. Dissertação de Mestrado – Recife 2005.
4. ALEXANDROV, N.; DENNIS, J. E. J.; LEWISAND, R. M.; TOREZON, V. *A Trust Region Framework for Managing the Use of Approximation Models in Optimization*. NASA/CR-201745. Hampton, VA. 1997. Technical Report No. 97-50.
5. BARTHELEMY, J. F. M.; HAFTKA, R. T. *Approximation concepts for optimum structural design - a review*. Structural Optimization, v. 5, p. 129-144, 1993.
6. BOX, G. E. P.; WILSON, K. B. *On the Experimental Attainment of Optimum Conditions (with discussion)*. Journal of the Royal Statistical Society Series B, v. 13, n. 1, p. 1-45, 1951.
7. CARMO, ANDRÉA; CUNHA, JANE; LIRA, DÁSIO. *Modelos substitutos baseados em aproximação de função*. Trabalho de Pesquisa – Agosto 2008. Recife-PE. UFPE.
8. COMPUTER MODELLING GROUP Ltd; *Imex 2005.10 User's Guide*. Manual de Referência; 2005.
9. CUERVO, CARLOS HERNÁN VARGAS. *Otimização do Cálculo de Parâmetros no Processo de Ajuste de Históricos de Produção usando PVM*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Mar, 1997. Dissertação (Mestrado).
10. DILLON, W.R.; GOLDSTEIN, M. *Multivariate analysis: methods and applications*. Wiley, New York: 1984.
11. ELDRED MICHAEL S., ADAMS, BRIAN M., GAY, DAVID M, SWILER, LAURA P., BOHNHOFF, WILLIAM J., EDDY, JOHN P., HART, WILLIAM E., WATSON, JEAN-PAUL, GRIFFIN, JOSH D., HOUGH, PATTY D., KOLDA, TAMMY G., WILLIAMS PAMELA J. AND MARTINEZ, MONICA L.. *DAKOTA, A Multilevel Parallel Object-Oriented Framework for Design Optimization, Parameter Estimation, Uncertainty Quantification, and Sensitivity Analysis* : Version 5.0 User's Manual, Sandia National Laboratories, USA, 2009.

12. ERTEKIN, T.; ABOU-KASSEM, J. H.; KING, G. R. *Basic Applied Reservoir Simulation*. Richardson, TX: Society of Petroleum Engineers, 2001.
13. FANCHI, JOHN R. *Principles of Applied Reservoir Simulation*. 3rd Edition, Elsevier GPP, 2006.
14. FORRESTER, A.; SOBESTER, A.; KEANE, A. *Engineering Design Via Surrogate Modeling: A Practical Guide*. Chichester: Wiley, 2008. 228 p. ISBN 0470060689.
15. GIUNTA, A. A.; ELDRED, M. S. *Implementation of a Trust Region Model Management Strategy in the DAKOTA Optimization Toolkit*. 8th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis and Optimization, AIAA-2000-4935. Long Beach, CA. 2000.
16. GUIMARÃES, LEONARDO; HOROWITZ, BERNARDO; AFONSO, SILVANA M. B. *Global Optimal Solutions for Reservoir Engineering Applications*. Conferência Internacional de Otimização em Engenharia – EngOpt 2008. Rio de Janeiro, Brasil.
17. JACOBS, J. H.; ETRNAN, L. F. P.; ROODA, J. E.; VAN KEULEN, F. *An object-oriented framework for sequential approximate optimization*. 9th AIAA/ISSMO Symposium on Multidisciplinary Analysis and Optimization, AIAA-2002-5635. Atlanta, GA. 2002.
18. KEANE, A. J.; NAIR, P. B. *Computational Approaches for Aerospace Design: The pursuit of Excellence*. Hoboken: John Willey & Sons Inc., 2005. 602 p. ISBN 0470855401.
19. LEITÃO, HÉLIO CHAGAS. *Ajuste de histórico automatizado através de otimização multivariada e paralelização externa*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1997. Dissertação (Mestrado).
20. LIRA, JOSÉ DÁSIO JR; WILLMERSDORF, RAMIRO; HOROWITZ, BERNARDO. *Propagação de Incertezas em Reservatórios de Petróleo usando a Expansão de KARHUNEM-LOËVE no Ambiente DAKOTA*. In: CONEM2010- VI Congresso Nacional de Engenharia Mecânica, 2010, Campina Grande - Paraíba.
21. MACHADO, A. VIEIRA. *Análise de sensibilidade aplicada a ajuste de histórico de produção usando o PVM*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1997. Dissertação (Mestrado).
22. MARQUES, NUNO CAVALHEIRO; MORGADO, CARMEM. *Octave: Guia de Estudo* Disponível em: http://ssdi.di.fct.unl.pt/pce/0405-1/material/aulas_praticas/octave/guia/guia_octave.html Acesso em 05 Fev. 2010.
23. MASCHIO, CÉLIO, VIDAL, COMPANE ALEXANDRE. E SCHIOZER, JOSÉ DENIS. *Integração do processo de ajuste de histórico com a modelagem geoestatística em reservatórios de petróleo*. Revista Brasileira de Geociências, Mar, 2008.

24. MASCHIO, CÉLIO E SCHIOZER, JOSÉ DENIS. *Ajuste de Histórico Assistido Usando Métodos de Otimização de Busca Direta*. Rio Oil & Gas Expo and Conference 2004, Out. 4-7, 2004, Rio de Janeiro, Brasil. IBP06204.
25. MEZZOMO, CRISTINA C. *Otimização de Estratégias de Recuperação para Campos de Petróleo*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2001. Dissertação (Mestrado).
26. OLIVEIRA, DIEGO F. BARBOSA. *Técnicas de Otimização da Produção para Reservatórios de Petróleo: Abordagens Sem Uso de Derivadas para Alocação Dinâmica das Vazões de Produção e Injeção*. Dissertação de Mestrado – Recife 2006
27. PENNA, DÉBORA DIAS JARDINS. *Definição da Árvore de Cenários de Afluências para Planejamento da Operação Energética de Médio Prazo*. Universidade Católica do Rio de Janeiro, Julho de 2009. Tese (Doutorado).
28. PIETROBOM, HILTON CLEBER. *Otimização Utilizando Funções Substitutas e Extração de Regras Difusas*. Tese de Doutorado. 2002. São Paulo. ITA.
29. *Programação matemática – Princípios básicos*. PUC- RIO. Certificação digital nº 0025018/CA. Disponível em: http://www.maxwell.lambda.ele.puc-rio.br/3332/3332_3.PDF. Acesso em 01 Fev. 2010.
30. RISSO, VALMIR F. *Ajuste de Histórico Utilizando Planejamento Estatístico e Combinação de Dados de Produção, Pressão e Mapas de Saturação*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2007. Dissertação (Mestrado).
31. RISSO, VALMIR F. E SCHIOZER, JOSÉ DENIS. *Ajuste de Modelos Numéricos de Campos de Petróleo Combinando Dados de Produção com Sísmica 4D*. Rio Oil & Gas Expo and Conference 2006, Set. 11-14, 2006, Rio de Janeiro, Brasil. IBP1285_06.
32. RODRIGUES, HELENA SOFIA FERREIRA. *Problema de otimização com restrições de complementaridade: uma aplicação ao mercado de energia elétrica*. Portugal: Universidade do Minho, Out 2005. Dissertação (Mestrado).
33. SALIBY, E.; e PACHECO, F.(2002) *An empirical evaluation of sampling methods in risk analysis simulation: Quasi-Monte Carlo, descriptive sampling, and latin Hypercube sampling*. Proceedings of the 2002 Winter simulation Conference. IEEE.
34. SANTOS, J. PEDRO. *Determinação de metodologia de ajuste automatizado de histórico*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2000. Dissertação (Mestrado).
35. SARMA, P., DURLOFSKY, L. J., AZIZ, K., 2008, Kernel Principal Component Analysis for Efficient Differentiable Parameterization of Multipoint Geostatistics. Math Geosci 40:3-32. Stanford University, Stanford, CA.

36. SCHIOZER, DENIS JOSÉ. Computação paralela aplicada à simulação numérica de reservatórios. Campinas: Faculdade de Engenharia Mecânica, Departamento de Engenharia de Petróleo, UNICAMP, 1997. 84 p. Dissertação (Livre Docência).
37. SCHOLKOPF, B., SMOLA, A, MULLER K., 1996, Nonlinear Component Analysis as a Kernel Eigenvalue Problem, Technical Report No. 44, Max-Planck Institut für biologische Kybernetik, Arbeitsgruppe Bülthoff.
38. SILVA, MARCELO FERREIRA DA. *Estratégias de Aproximação para Otimização Estrutural*. Dissertação de Mestrado – Nov 2009. Recife-PE. UFPE.
39. *Tópicos sobre regressão linear múltipla*. Disponível em: <http://www.inf.ufsc.br/~ogliari/arquivos/topicossobreregressaoineararmultipla.ppt>. Acesso em 05 Marc. 2010.
40. TOROPOV, V. V. *Simulation approach to structural optimization*. Structural Optimization, v. 1, p. 37-46, 1989.
41. T.W. SIMPSON, J.D. PEPLINSKI, P.N. KOCH, AND J.K. ALLEN. *Metamodels for computer based Engineering Design: Survey and recommendations*. Engineering with Computers Vol. 17:129-150, (2001).
42. WATTS, J. W. *Reservoir Simulation: past, present and future*. Society of Petroleum Engineers. Paper 38441. In: 1997 SPE RESERVOIR SIMULATION SYMPOSIUM. Dallas, 8-11 de junho de 1997.
43. YERGIN, D. *O Petróleo: Uma História de Ganância, Dinheiro e Poder*. Tradução de Leila Marina U. Di Natale, Maria Cristina Guimarães, Maria Christina L. de Goes. São Paulo: Scritta, 1993. Título original: The prize: the epic quest for oil money and power.