



Universidade Federal de Pernambuco
Centro de Tecnologia e Geociências
Pós-Graduação em Engenharia Civil



ANP/PRH-26

Tese de Doutorado

OTIMIZAÇÃO COM MODELOS SUBSTITUTOS CONSIDERANDO INCERTEZAS EM RESERVATÓRIOS DE PETRÓLEO

JOSÉ DÁSIO DE LIRA JUNIOR

Orientador: Ramiro Brito Willmersdorf, Ph. D.

Co-Orientador: Bernardo Horowitz, Ph. D.

Recife – PE

Janeiro de 2012

OTIMIZAÇÃO COM MODELOS SUBSTITUTOS CONSIDERANDO INCERTEZAS EM RESERVATÓRIOS DE PETRÓLEO

JOSÉ DÁSIO DE LIRA JUNIOR

Tese de Doutorado submetida ao Corpo de Docente do Curso de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, como parte dos requisitos necessários à obtenção do grau de Doutor em Ciências em Engenharia Civil.

Área de Concentração: Estruturas (Engenharia de Reservatórios)

Ramiro Brito Willmersdorf, Ph. D.

Orientador

Bernardo Horowitz, Ph. D.

Co-Orientador

Recife, Pernambuco, Brasil

José Dásio de Lira Junior, Janeiro de 2012

Catálogo na fonte
Bibliotecária Raquel Cortizo, CRB-4 664

L768o Lira Junior, José Dásio de
Otimização com modelos substitutos considerando incertezas em reservatórios de petróleo / José Dásio de Lira Junior. Recife: O Autor, 2012.
xix, 125 folhas, il., gráfs., tabs., figs.

Orientador: Prof. Dr:Ramiro Brito Willmersdorf.
Tese (Doutorado)– Universidade Federal de Pernambuco.
CTG. Programa de Pós-Graduação em Engenharia Civil, 2012
Inclui Referências Bibliográficas.

1. Engenharia Civil 2. Engenharia de petróleo 3.Otimização
4. Simulação de reservatórios. 5. Incertezas. 6. Ajuste de histórico I. Willmersdorf, Ramiro Brito (orientador). II. Título.

624 CDD (22. ed.)

UFPE
BCTG/2012-047



UNIVERSIDADE FEDERAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL
A comissão examinadora da Defesa de Tese de Doutorado

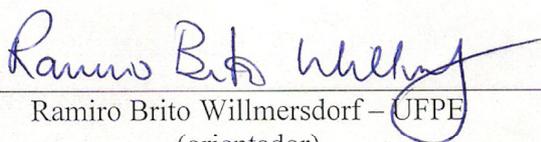
**OTIMIZAÇÃO UTILIZANDO MODELOS SUBSTITUTOS
CONSIDERANDO INCERTEZAS EM RESERVATÓRIO DE PETRÓLEO**

defendida por

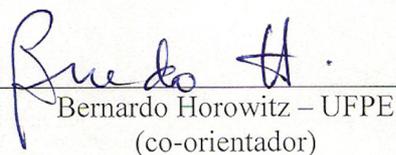
José Dásio de Lira Junior

Considera o candidato APROVADO

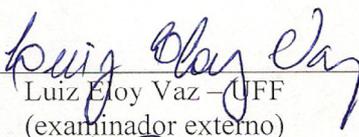
Recife, 20 de janeiro de 2012



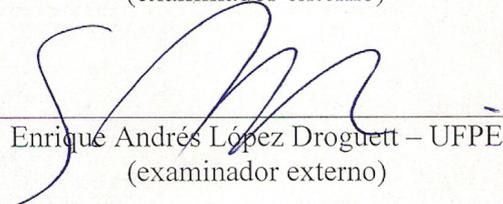
Ramiro Brito Willmersdorf – UFPE
(orientador)



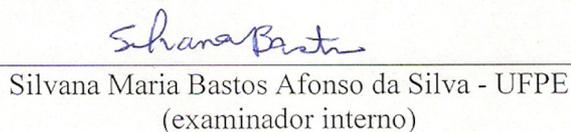
Bernardo Horowitz – UFPE
(co-orientador)



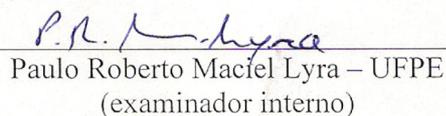
Luiz Eloy Vaz – UFF
(examinador externo)



Enrique Andrés López Droguett – UFPE
(examinador externo)



Silvana Maria Bastos Afonso da Silva - UFPE
(examinador interno)



Paulo Roberto Maciel Lyra – UFPE
(examinador interno)

Dedicatória

Dedico este trabalho a minha família, fonte de energia necessária para acordar, trabalhar, lutar e sonhar.

Aos meus pais José Dásio e Luzileide, meu eterno agradecimento. Meu Pai exemplo de superação, minha Mãe exemplo de amor e fé.

A minha esposa Camila, agradeço o amor, carinho e compreensão.

Aos meus irmãos Cibele e Rafael agradeço pelo apoio em todos os momentos.

Agradecimentos

A ANP – Agência Nacional de Petróleo, em nome de programa de recursos humanos PRH-26, pelo suporte financeiro durante o período de desenvolvimento deste trabalho.

Ao meu orientador Prof. Ramiro Brito Willmersdorf, agradeço por todo o conhecimento que me disponibilizou, com certeza seus ensinamentos foram fundamentais em minha formação profissional.

Aos professores Bernardo Horowitz e Silvana Maria Bastos Afonso da Silva, agradeço pelo apoio e orientações durante todo o período deste trabalho.

A todos os professores, que contribuíram decisivamente em minha formação profissional e pessoal.

Aos colegas da pós-graduação da UFPE, Liliane, Leonardo, Renato, Juliana, Rogério, Darlan, Alessandro, Antonio, Andrea, pela amizade, incentivo e convívio durante esta importante etapa de minha vida.

Aos professores e amigos do IFPE, Gustavo, Ângelo, Rodrigo, Carlos, Clóvis, Pablo, Lídice e Jacek pela ajuda e incentivo, principalmente na etapa final deste trabalho.

Resumo

A busca por condições ótimas para a produção de óleo e gás é um dos maiores desafios no campo da engenharia de petróleo. A necessidade de tomar decisões em intervalos de tempo cada vez menor, associada a uma série de limitações, tais como simulações de alto custo computacional, exigem elevados investimentos no desenvolvimento de novas ferramentas computacionais.

Este trabalho apresenta ferramentas computacionais para alocação dinâmica das vazões nos poços de produção e injeção, e ajuste de histórico. As incertezas relacionadas às propriedades petrofísicas, como o campo de permeabilidades serão consideradas no problema de alocação de vazões.

O modelo “black –oil” é utilizado neste trabalho, e as simulações são feitas com um simulador comercial. O campo de permeabilidades é considerado como um campo estocástico, caracterizando a incerteza como uma variável na entrada do modelo. Os campos estocásticos de entrada são descritos com a expansão de Karhunen-Loeve, e as respostas estocásticas de interesse são expressas com expansão em caos polinomial e também com a colocação estocástica. A utilização da expansão de Karhunen-Loeve diretamente requer um alto custo computacional, para minimizar este problema é utilizada a técnica de análise dos componentes principais utilizando a matriz núcleo (KPCA). Esta metodologia quando aplicada na forma linear somente preserva os momentos de primeira e segunda ordem do campo estocástico, sendo necessária a utilização da metodologia KPCA não linear para representar os momentos de ordem maior que dois.

Neste trabalho são utilizados modelos substitutos, que uma vez construídos possibilitam uma redução no custo computacional. Outra vantagem na utilização de modelos substitutos é que os mesmos permitem desenvolver estudos de otimização quando não se tem informações sobre as derivadas das equações do problema a ser simulado. Serão apresentadas diferentes metodologias para a geração de modelos substitutos, tais como, Krigagem, MARS e Processo Gaussiano. Para gerar os modelos, diferentes técnicas de amostragem são estudadas, tais como, Quase-Monte Carlo (QMC), Hipercubo latino (LHS) e Tesselação de Voronoi (CVT).

Os modelos substitutos são utilizados juntamente com a estratégia de otimização por aproximação sequencial (SAO). Esta metodologia decompõe o processo de otimização em subproblemas, onde cada subproblema é restrito a uma região do espaço de projeto (região de confiança). No caso de otimização considerando incertezas é utilizada a metodologia de camadas e aninhamento.

Estudos de caso em reservatório sob injeção de água ou gás são desenvolvidos. Os resultados mostram que as metodologias de modelos substitutos são uma alternativa viável quando não se têm acesso as derivadas do problema. Os casos de otimização das alocações dinâmicas das vazões de produção mostram que as metodologias apresentadas alcançam um considerável acréscimo no valor presente líquido. No caso do ajuste de histórico, as metodologias utilizadas mostram uma boa capacidade preditiva.

Palavras - Chaves: Engenharia de Petróleo, Otimização, Simulação de Reservatórios, Incertezas, Ajuste de Histórico.

Abstract

The search for optimal conditions for the production of oil and gas is one of the major challenges in the field of petroleum engineering. The need to make decisions in small time intervals, associated with a number of limitations such as high computational cost of simulations require large investments in developing new computational tools.

This research presents computational tools for dynamic allocation of flows in production and injection wells, and history matching. The uncertainties related to the petrophysical properties such as permeability field will be considered in flow allocation problem.

The black oil model is used in this work, and simulations are made with a commercial simulator. The permeability field is considered as a stochastic field, characterizing the uncertainty as a variable in the model input. The stochastic input fields are described with the Karhunen-Loeve expansion, and the stochastic responses of interest are expressed with polynomial chaos expansion and also the stochastic collocation. The use of the Karhunen-Loeve expansion directly requires a high computational cost. In this work the kernel principal component analysis (KPCA) technique was used to minimize these problems. This methodology when applied in a linear form only preserves the moments of the first and second order stochastic field, requiring the use of nonlinear KPCA methodology to represent the moments of order greater than two.

Surrogate models were used in this work, and once built it allows a reduction in the computational cost. Another advantage of using surrogate models is that they allow to develop optimization studies when there is no information about the gradients of the equations of the problem. It will be presented different methods for generating surrogate models such as Kriging, MARS, and Gaussian Process. To generate the models, different sampling techniques are studied, such as Quasi-Monte Carlo (QMC), Latin Hypercube (LHS) and Centroidal Voronoi Tessellation (CVT).

In management production studies, and history matching, the substitute model are used in conjunction with the sequential approximate optimization approach (SAO). This methodology breaks down the optimization process in subproblems where each

subproblem is restricted to a subregion of design space (trust region). The layering and nesting technique was used in optimization under uncertainties problems.

Case studies on reservoir water or gas injection are developed, and the results show that the methodologies of surrogate models are a viable alternative when you do not have access to the gradients of the problem. The production management studied cases show that the optimization methods presented here have achieved a considerable increase in the net present value. In the case of history matching, the methods used show a good predictive ability.

Keywords: Petroleum Engineering, Optimization, Reservoir Simulation, Uncertainty, History Matching

Lista de Símbolos

Letras Romanas

- b – comprimento de correlação
- C – matriz de covariância
- d – taxa de desconto
 - dimensão do espaço vetorial
 - ordem do polinômio
- d_{obs} – dados observados
- D – espaço de projeto
- E – matriz dos autovetores
 - valor esperado
- f – função; função objetivo
- F – fluxo de caixa
 - espaço vetorial de alta ordem
- I – conjunto dos índices dos poços injetores
- K – matriz núcleo
- m – propriedades do reservatório
- n – número total de amostras
- n_t – número de intervalos de tempo
- n_{dv} – número total de variáveis
- N_c – número total de blocos do reservatório

N_r – número de realizações

p – índice que representa um poço p

P – conjunto dos índices dos poços produtores

$q_{p,t}$ – vazão do poço p no intervalo de tempo t

$Q_{l,max}$ – vazão máxima de produção permitida

$Q_{Inj,max}$ – vazão máxima de injeção permitida

r – vetor de correlação

\mathbf{R} – matriz de correlação

S – desvio padrão

t – índice que representa o intervalo de tempo

\mathbf{u} – variáveis de estado

\mathbf{u} – variáveis de controle

x – variáveis de projeto

\mathbf{x} – vetor de variáveis

\mathbf{X} – conjunto de amostras

$\mathbf{x}_{p,t}$ – variáveis de controle do problema no poço p , no intervalo de tempo t

\mathbf{x}_c^k – ponto central da região de confiança na iteração k

\mathbf{x}_l^k – limites superiores das variáveis de projeto na iteração k

\mathbf{x}_u^k – limites inferiores das variáveis de projeto na iteração k

$x_{p,t}^l$ – limite inferior da variável de controle no poço p no intervalo de tempo t

$x_{p,t}^u$ – limite superior da variável de controle no poço p no intervalo de tempo t

w – parâmetros de função

y_k – conjunto de realizações

Y – realizações no espaço F

Z – erro de função

Letras Gregas

θ_k – parâmetros de correlação

θ – evento independente

$\mathbf{\alpha}$ – matriz de autovetores

β – parâmetros de função

λ – autovalor

ξ – vetor de variáveis aleatórias não correlacionadas

ϵ – erros relacionados aos dados observados.

Φ – mapeamento não-linear

σ_E – desvio padrão

Λ – matriz diagonal de autovalores

ϕ_n – polinômios Hermitianos de ordem n

Ψ – matriz de polinômios

Δ^k – tamanho da região de confiança

ρ_D – função densidade de probabilidade

Lista de Acrônimos

- ANNEL – Agência Nacional de Energia Elétrica
- ANP – Agência Nacional de Petróleo
- BHP (*Bottom Hole Pressure*) – Pressão de Fundo de Poço
- CVT(*Centroidal Voronoi Telsselations*) – Tesselação de Voronoi
- DOE (*Design of Experiments*) – Projeto de Experimentos
- GP (*Gaussian Process*) – Processo Gaussiano
- IEA (International Energy Agency) – Agência Internacional de Energia
- KPCA (*Kernel Principal Component Analysis*) – Análise dos Componentes Principais Utilizando a Matriz Núcleo
- K-L – Karhunen Loeve
- LHS (*Latin Hypercube Sampling*) – Hipercubo Latino
- LCVT (*Latin Centroidal Voronoi Telsselations*) – Tesselação de Voronoi Latinizada
- MME – Ministério de Minas e Energia
- MARS (*Multivariate Adaptive Regression Splines*) – Regressão Adaptativa Multivariada por Splines
- MSE (*Mean Squared Error*) – Erro Quadrático Médio
- MC – Monte Carlo
- OPEP – Organização dos Países Exportadores de Petróleo
- OOU (*Optimization under uncertainty*) – Otimização considerando Incertezas
- PIB – Produto Interno Bruto
- PCA (*Principal Component Analysis*) – Análise dos Componentes Principais
- PCE (*Polynomial Chaos Expansion*) – Expansão em Chaos Polinomial

QMC (*Quasi-Monte Carlo*)

RMSE (*Root Mean Square Error*) – Erro Quadrático Médio

SAO (*Sequential Approximate Optimization*) – Otimização por Aproximação
Sequencial

SVD (*Single Value Decomposition*) – Decomposição em Valores Singulares

SPE (*The Society of Petroleum Engineers*) – Sociedade de Engenheiros de
Petróleo

UQ (*Uncertainty quantification*) - Propagação de Incertezas

VPL – Valor Presente Líquido

WC (*Water Cut*) – Corte de Água

Índice

1. Introdução	1
1.1. Motivações Econômicas	1
1.2. Motivações Tecnológicas	5
1.3. Objetivos da Pesquisa	7
1.4. Definição do Problema de Otimização das Alocações Dinâmicas das Vazões	9
1.5. Definição do Problema de Ajuste de Histórico	10
1.6. Contribuições do Trabalho	11
1.7. Organização do Trabalho	12
2. Revisão Bibliográfica	14
2.1. Otimização na Produção de Petróleo	14
2.2. A incerteza na Caracterização do Reservatório	18
2.3. A Evolução do Processo de Ajuste de Histórico	19
3. Modelos Substitutos	22
3.1. Introdução	22
3.2. Modelos Substitutos Obtidos por Interpolação de Dados	24
3.3. Métodos de Amostragem	25
3.3.1. Método de Quasi-Monte Carlo (QMC)	26
3.3.2. Método de Tesselação de Voronoi (CVT)	27
3.3.3. Hipercubo Latino (LHS)	29

3.4. Modelos Substitutos	30
3.4.1. Krigagem	30
3.4.2. MARS	33
3.5. Estudo de Caso – Injeção de Água em Reservatório com 3 Poços .	37
4. Propagação de Incerteza	49
4.1. Introdução	49
4.2. Expansão de Karhunen-Loeve (K-L)	52
4.3. Expansão de Karhunen-Loeve com a Utilização da Matriz Núcleo (KPCA)	54
4.4. Análise dos Componentes Principais Não-Linear (KPCA Não Linear)	56
4.4.1. Problema da Pré-Imagem	59
4.5. Expansão em Caos Polinomial	61
4.6. Colocação Estocástica	64
4.7. Estudo de Caso – Injeção de Gás em Reservatório com 2 poços .	65
4.7.1. Problema com 1 Variável Incerta	66
4.7.2. Problema com 3 Variáveis Incertas	70
4.7.3. Problema de Alta Dimensão	72
5. Otimização com Simulação	77
5.1. Introdução	77
5.2. Otimização por Aproximação Seqüencial	78
5.3. Otimização com Simulação Estocástica	81
5.4. Estudo de caso – Injeção de Água em Reservatório com 3 Poços .	83
5.4.1. Caso 1 – 2 Variáveis de Controle e 1 Variável Incerta .	83
5.4.2. Caso 2 – 2 Variáveis de Controle e 10 Variáveis Incertas .	85
6. Ajuste de Histórico	96
6.1. Introdução	96
6.2. Metodologia de Ajuste	99
6.2.1. Aplicação Utilizando a Expansão de Karhunen-Loeve .	100

6.3. Estudo de Caso – Injeção de Água em Reservatório com 3 poços .	101
6.3.1. Ajuste Utilizando KPCA Linear	103
6.3.2. Ajuste Utilizando KPCA Não Linear	106
7. Conclusões e Trabalhos Futuros	109
7.1. Conclusões	109
7.2. Trabalhos Futuros	111

Lista de Tabelas

3.1 Condições de restrição nos poços.	39
3.2 Resultados do erro RMSE para a avaliação do VPL: caso C1.	43
3.3 Resultados do erro RMSE para a avaliação do VPL: caso C2.	44
3.4 Resultados do erro RMSE para a avaliação do VPL: caso C3.	44
3.5 Resultados do erro RMSE para a avaliação do VPL: caso C4.	44
4.1 Resultado para o método de Monte Carlo.	67
4.2 Caos polinomial com 1 variável incerta.	69
4.3 Colocação Estocástica.	70
4.4 Resultado para o método de Monte Carlo, com 3 variáveis incertas.	71
4.5 Expansão em caos polinomial, com 3 variáveis incertas.	71
4.6 Resultado para o método de Monte Carlo, alta dimensão.	74
4.7 Expansão em caos polinomial, alta dimensão.	76
5.1 Valor inicial e resultado da otimização sob incerteza.	85
5.2 Valor inicial e resultado da otimização para o caso 2 (otimização determinística).	88
5.3 Valor inicial e resultado da otimização para o caso 2 (otimização estocástica).	91
5.4 Valor esperado e desvio padrão do VPL para estudos de propagação de incertezas).	92
5.5 Vazões e VPL ótimos para o processo de otimização determinística e otimização sob incerteza	93
5.6 Resultados para o processo de verificação da otimização sob incerteza.	94

Lista de Figuras

1.1 Gráfico da variação do PIB e variação do consumo de energia.....	2
1.2 Participação das diversas fontes de energia no consumo mundial.....	3
1.3 Evolução da produção de petróleo no período de 2000 a 2009.	4
1.4 Esquema de um poço inteligente	7
3.1 Amostragem gerada pelo método de Monte Carlo.....	26
3.2 Amostragem gerada pelo método de Quasi-Monte Carlo.....	27
3.3 Conjunto inicial de pontos geradores.....	28
3.4 O Método de Tesselação de Voronoi para os pontos da Figura 3.3.....	28
3.5 O método de Tesselação de Voronoi (CVT) após atingir a condição final de uniformidade.....	28
3.6 Amostragem gerada pelo método LHS num espaço bidimensional.....	29
3.7 Funções da base utilizada no MARS.....	34
3.8 Aproximação no espaço bidimensional com aplicação do MARS.....	35
3.9 Função $h(X)$ para Amostras no Espaço Tridimensional.....	36
3.10 Esquema do reservatório, mostrando a localização dos poços e as regiões de permeabilidade horizontal	37
3.11 Amostras obtidas por DOE na aplicação de engenharia de reservatórios: (a) QMC, (b) LCVT and (c) LHS.....	38
3.12 Superfícies de VPL para o caso C1 (Nenhuma Restrição).....	39
3.13 Superfícies de VPL para o caso C2 (Restrição de BHP).....	40
3.14 Superfícies de VPL para o caso C3 (Restrição de corte de água - WC).....	40
3.15 Superfícies de VPL para o caso C4 (Restrição de BHP e WC).....	41
3.16 Contornos da função de VPL para o caso C1 (Nenhuma Restrição).....	41

3.17 Contornos da função de VPL para o caso C2 (Restrição de BHP).....	42
3.18 Contornos da função de VPL para o caso C3 (Restrição de Corte de Água - WC).....	42
3.19 Contornos da função de VPL para o caso C4 (Restrição de BHP e WC).....	43
3.20 Superfícies do VPL para a condição de restrição do caso C1: (a) K , (b) GP e (c) MARS.....	45
3.21 Contornos do VPL para a condição de restrição do caso C1: (a) K , (b) GP e (c) MARS.....	45
3.22 Superfícies do VPL para a condição de restrição do caso C2: (a) K , (b) GP e (c) MARS.....	45
3.23 Contornos do VPL para a condição de restrição do caso C2: (a) K , (b) GP e (c) MARS.....	46
3.24 Superfícies do VPL para a condição de restrição do caso C3: (a) K , (b) GP e (c) MARS.....	46
3.25 Contornos do VPL para a condição de restrição do caso C3: (a) K , (b) GP e (c) MARS.....	46
3.26 Superfícies do VPL para a condição de Restrição do caso C4: (a) K , (b) GP e (c) MARS.....	47
3.27 Contornos do VPL para a condição de restrição do caso C4: (a) K , (b) GP e (c) MARS.....	47
4.1 Idéia básica da técnica KPCA	56
4.2 Modelo do reservatório com injeção de gás.....	65
4.3 Histograma das variáveis de entrada (Permeabilidade) e de saída (VPL).....	68
4.4 Magnitude dos autovalores da Matriz de Covariância.....	73
4.5 Visualização da realização de permeabilidade obtida a partir da expansão de K-L: (a) Vista 2d, (b) Vista 3d.....	74
5.1 Esquema da metodologia SAO.....	81
5.2 Metodologia camadas e aninhamento.....	82
5.3 Modelo do reservatório sob injeção de água.....	84
5.4 Realizações do campo de permeabilidades em escala real.....	86
5.5 Realizações do campo de permeabilidades em escala logarítmica.....	87
5.6 Realização escolhida para estudo de otimização determinística.....	88

5.7 Curvas de produção acumulada de óleo e água	
para os casos inicial e otimizado.....	89
5.8 Curvas de vazões de líquidos nos poços produtores para o caso inicial.....	89
5.9 Curvas de vazões de líquidos nos poços produtores para o caso ótimo.....	90
5.10 Curvas de cortes de água para os casos inicial e otimizado.....	90
5.11 Gráfico dos VPL referentes à Tabela 5.6.....	94
6.1 Curvas representando o processo de ajuste de histórico.....	98
6.2 Modelo do reservatório para o estudo de caso.....	102
6.3 Realizações possíveis para o estudo de caso (escala logarítmica).....	102
6.4 Realização escolhida como caso observado (escala logarítmica).....	103
6.5 Curvas de produção acumulada de óleo obtidas	
no processo de ajuste de histórico.....	104
6.6 Extrapolação das curvas de produção acumulada de óleo obtidas	
no processo de ajuste de histórico.....	104
6.7 Estimativa inicial do campo de permeabilidades.....	105
6.8 Campo de Permeabilidades obtido com o processo	
de ajuste de histórico.....	105
6.9 Curvas de produção acumulada de óleo obtidas	
no processo de ajuste de histórico.....	106
6.10 Extrapolação das curvas de produção acumulada	
de óleo obtidas no processo de ajuste de histórico.....	107
6.11 Estimativa inicial do campo de permeabilidades.....	107
6.12 Campo de permeabilidades obtido com o processo de ajuste de histórico.....	108

Capítulo 1

Introdução

Este trabalho está situado na área da engenharia de reservatórios, mais precisamente na utilização de ferramentas computacionais para otimização da produção de óleo e gás. No contexto da otimização da produção em reservatórios de petróleo, a pesquisa desenvolvida tem ênfase no estudo da alocação dinâmica das vazões nos poços de produção e injeção. Este tipo de otimização proporciona uma forma de controle das vazões nos poços com objetivo de se atingir um lucro máximo. Incertezas relacionadas às propriedades petrofísicas, como permeabilidade, serão consideradas. Além da otimização da produção, as metodologias desenvolvidas serão aplicadas para ajuste de histórico. Neste capítulo serão apresentadas as motivações encontradas para o desenvolvimento do trabalho, os objetivos da pesquisa, a definição do problema, além de uma apresentação sobre a organização do trabalho.

1.1 Motivações Econômicas

O desenvolvimento industrial possibilitou a sociedade uma série de benefícios nos mais variados campos, tais como, automotivo, aeronáutico, naval, agroindustrial e petroquímico. Entretanto, o caminho de qualquer nação para alcançar o desejado sucesso econômico apresenta sérios obstáculos, e com certeza um dos principais é como suprir o aumento da demanda energética. Apesar de ser um obstáculo ao desenvolvimento econômico, o alto consumo energético é um dos principais indicadores de quali-

dade de vida em uma sociedade. O atlas de energia do Brasil (ANEEL, 2008) afirma a importância do acesso a energia da seguinte forma: “Uma das variáveis para definir um país como desenvolvido é a facilidade de acesso da população ao serviço de energia”, no mesmo documento temos a seguinte afirmação: “A energia é o fator determinante para o desenvolvimento econômico e social ao fornecer apoio mecânico, térmico e elétrico às ações humanas.”

O consumo energético mundial cresce proporcionalmente ao crescimento econômico. Esta relação pode ser verificada na Figura 1.1 (ANEEL, 2008), onde no período de 1998 a 2007, temos a taxa de variação do PIB mundial e do consumo energético em toneladas equivalentes de petróleo. No período de 2003 a 2007 o consumo energético acumulado aumentou em 13%, passando de 9.828 milhões de toneladas equivalentes de petróleo (tep) em 2003, para 11.099 milhões em 2007.

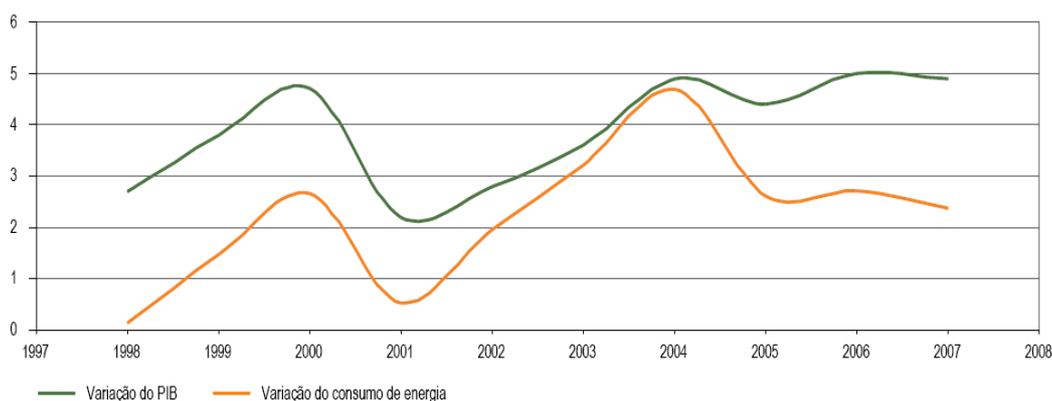


Figura 1.1: Gráfico da variação do PIB e variação do consumo de energia (ANEEL, 2008).

Na edição do *Key World Energy Statistics* de 2010 (IEA, 2010), o consumo total de energia no período de 1973 a 2008, passou de 4.676 milhões de tep para 8.428 milhões de tep, representando um aumento de aproximadamente 80%. Neste quadro, Petróleo e gás representam aproximadamente 60% do consumo total de energia (IEA 2010). Na Figura 1.2 são mostradas as participações de diversas fontes de energia no

consumo do período compreendido entre 1973 e 2006. Os números são do atlas de energia elétrica do Brasil (ANEEL, 2008).

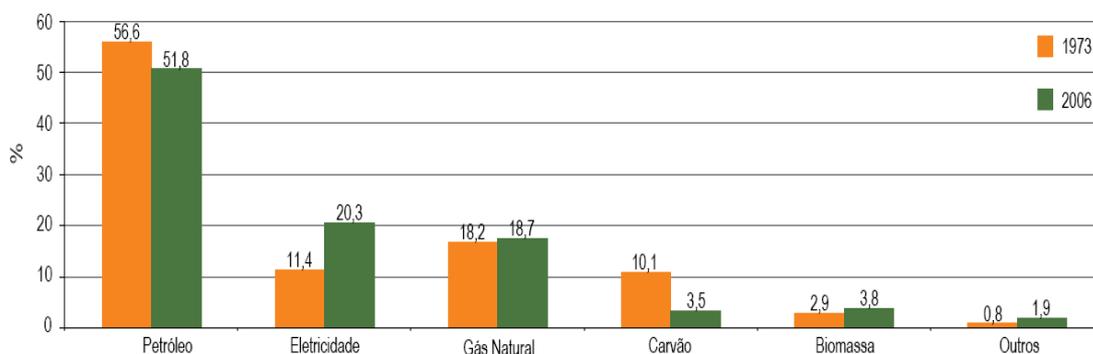


Figura 1.2: Participação das diversas fontes de energia no consumo mundial (ANEEL, 2008).

Um grande número de variáveis influencia diretamente e indiretamente nas previsões de demanda e preço do petróleo e gás. Entre estas variáveis é possível citar: crescimento econômico mundial, evolução das reservas e da produção mundial, variação dos estoques, evolução do perfil de demanda, eficiência energética, preço dos produtos substitutos, condições climáticas, ocorrência de eventos de geopolítica, estratégias de mercado dos produtores (em particular, da OPEP) e dos grandes países consumidores (política energética, etc.), especulação nos mercados futuros (MME, 2008).

Segundo o relatório *World Energy Outlook 2010* (IEA, 2010), a demanda de energia primária, que é o recurso energético que se encontra disponível na natureza (petróleo, gás natural, energia hídrica, energia eólica, biomassa, solar) aumentará 36% entre 2008 e 2035, passando aproximadamente de 12.300 milhões de toneladas de equivalente de petróleo (Mtep) para 16.700 Mtep, correspondendo a uma média anual de 1,2%. Petróleo e gás ainda serão em 2030 as principais fontes energéticas mundiais, representando em torno de 60% da matriz energética mundial (IEA, 2010). Estudos apresentados pela Agência Internacional de Energia (IEA, 2010) mostram que o consumo mundial de petróleo em 2030 deverá estar por volta de 100 milhões de barris/dia. Para se ter uma idéia o Brasil atingiu em 2009 uma produção de 2 milhões de barris/dia,

enquanto a produção mundial atingiu 79,9 milhões de barris/dia (ANP, 2010). Na Figura 1.3 temos a evolução da produção mundial de petróleo no período de 2000 a 2009.

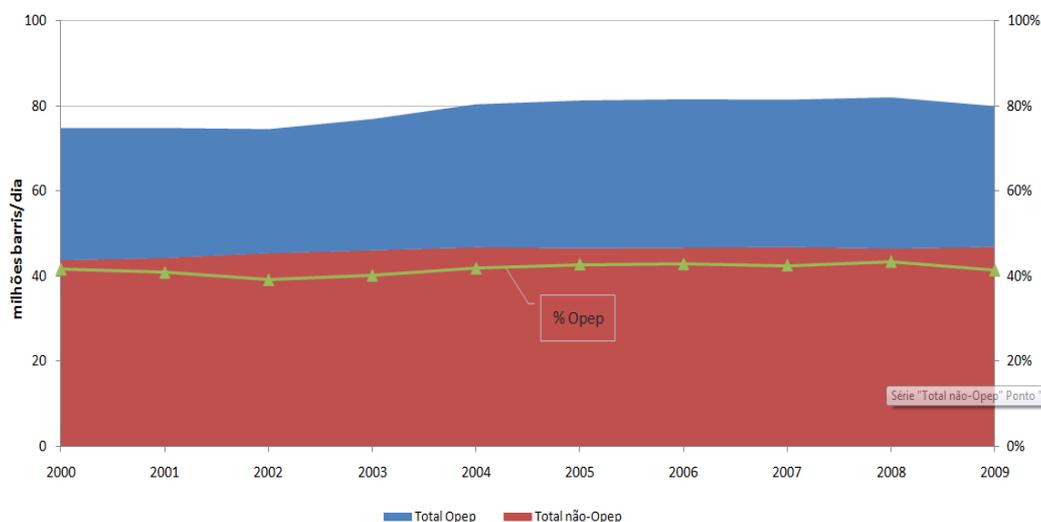


Figura 1.3: Evolução da produção de petróleo no período de 2000 a 2009 (ANP, 2010).

Neste contexto de necessidade energética e levando em consideração que petróleo e gás são fontes de energia não renováveis, é cada vez maior a necessidade de se otimizar a produção de petróleo e gás. Um aspecto importante relacionado aos reservatórios de petróleo é o fator de recuperação que, considerando uma média em reservatórios espalhados por todos os continentes, está situado por volta de 30% (Thomas, 2001; Rosa et al, 2006), ou seja, 70% do óleo continua preso ao reservatório. Estes aspectos mostram a necessidade de fortes investimentos em pesquisa e desenvolvimento, para que novas metodologias possam reduzir custos, riscos, aumentar o fator de recuperação e claro elevar a retorno financeiro de toda a produção. É importante mencionar que os resultados numéricos são fundamentais para definição da estratégia de produção a ser aplicada em determinado reservatório, como também durante todo o período de gerenciamento do reservatório.

Outro importante fator de motivação é a descoberta das reservas de óleo brasileiras na camada do pré-sal, localizadas em torno de oito mil metros de profundidade abai-

xo do leito do mar. A extração de petróleo no pré-sal exigirá um elevado investimento em pesquisa e no desenvolvimento de soluções inovadoras que irão permitir a produção de óleo e gás com viabilidade econômica e ambiental. No cenário relacionado à produção de hidrocarbonetos do pré-sal, a utilização de ferramentas de simulação numérica ocupará importante lugar no conjunto de metodologias de auxílio para o processo de tomada de decisões e gerenciamento integrado dos reservatórios.

1.2 Motivações Tecnológicas

O gerenciamento integrado de campos de petróleo é uma das atividades de maior importância durante todo o período de exploração e produção dos reservatórios (Satter e Thakur, 1994). Decisões precisam ser tomadas num ambiente de incertezas e alto risco, levando em consideração o crescente nível de investimento necessário para a exploração de campos, principalmente quando estes estão no alto mar. Várias áreas do conhecimento estão envolvidas no ambiente do gerenciamento de reservatórios, entre elas podemos citar: engenharia de reservatórios, geologia, geofísica, economia, estratégias de decisão, meio ambiente, além de áreas da engenharia de petróleo (equipamentos de superfícies, perfuração de poços, avaliação de formações e outras) (Thomas, 2001).

A utilização de ferramentas de simulação numérica é indispensável no ambiente de exploração e produção (E&P) de reservatórios de óleo e gás. Técnicas computacionais são cada vez mais aplicadas no ambiente da engenharia de reservatórios, temos como exemplo: simulação de fluxo em meio poroso, otimização da produção, posicionamento de poços, e ajuste de histórico.

A otimização da produção em reservatórios de petróleo envolve modelos computacionais complexos e com grande demanda computacional. Adicionalmente, o conhecimento sobre o reservatório é sempre incerto e esta incerteza deve ser considerada nas simulações computacionais de reservatório. Nos dias atuais a consideração das incertezas geológicas, tecnológicas e econômicas é essencial no desenvolvimento de simulações numéricas de reservatório de petróleo, possibilitando maior eficiência na busca de estimativas ótimas de produção e lucro.

No contexto da otimização da produção, este trabalho tem ênfase no estudo de alocação dinâmica das vazões nos poços de produção e injeção (Oliveira, 2006). Este tipo de otimização proporciona uma forma de controle das vazões nos poços com objetivo de se atingir um lucro ótimo.

Os níveis de incerteza são diferentes em cada fase da vida útil de um campo de petróleo, sendo assim é importante a consideração sobre em que fase se encontra o reservatório. As fases da vida útil de um reservatório são exploração, avaliação, desenvolvimento, produção (primária, secundária e terciária) e abandono. Na fase inicial de vida do reservatório, poucos são os dados geológicos disponíveis. Os dados iniciais são obtidos a partir de poucos poços perfurados e dados sísmicos.

A otimização da alocação de vazões nos poços na atualidade está relacionada a um avanço na tecnologia de poços, mais precisamente no desenvolvimento de poços inteligentes (Brouwer, 2004). No passado, os poços convencionais em sua maioria verticais eram os mais utilizados. Estes poços possuem as vantagens de baixo custo e fácil construção, em contrapartida a área de contato com o reservatório é pequena e não permitem alto nível de controle. Os poços inteligentes são poços não convencionais (horizontais e multilaterais) com completações inteligentes (instrumentação: válvulas e sensores). A tecnologia de poços inteligentes permite o desenvolvimento e aplicação de sistemas computacionais de controle. Na Figura 1.4 é apresentado um esquema de funcionamento de um poço inteligente.

Reconhecida a importância das simulações numéricas de otimização sob incerteza, um grande obstáculo é encontrado, o elevado custo computacional das simulações. Uma única simulação de reservatório pode durar dias, enquanto que um estudo de otimização sob incerteza pode chegar facilmente a 50.000 simulações. Logo, é necessário desenvolver metodologias que consigam reduzir substancialmente o custo computacional. O uso de computação paralela também é necessário, e será aplicado neste trabalho.

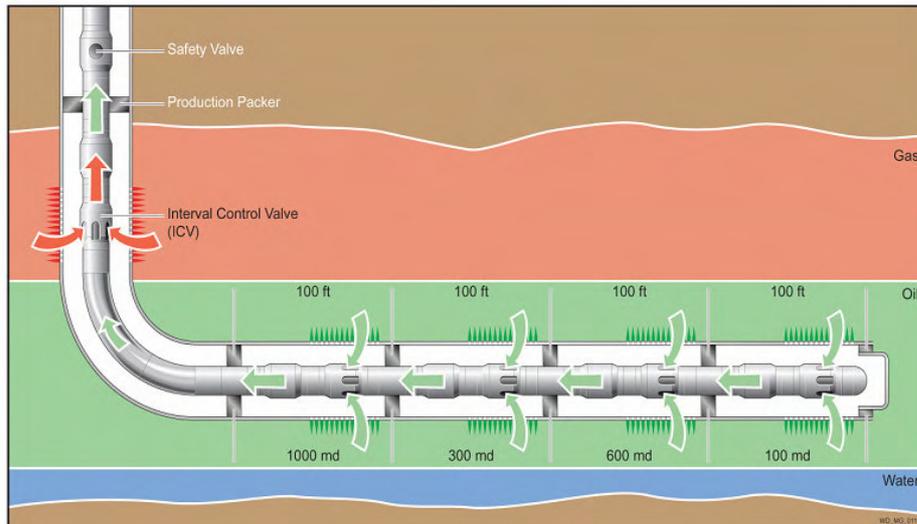


Figura 1.4: Esquema de um poço inteligente (Sarma, 2006).

1.3 Objetivos da Pesquisa

Este trabalho tem como objetivo o estudo e desenvolvimento de um sistema computacional visando fornecer dados que auxiliem o processo de gerenciamento em reservatórios de óleo e gás. Neste sistema, processos de otimização e propagação de incertezas da produção serão desenvolvidos de uma forma integrada. As metodologias desenvolvidas também serão utilizadas para realização de ajuste de histórico.

Na etapa de gerenciamento da produção, as variáveis de controle serão as alocações dinâmicas das vazões de produção nos poços. O processo de otimização será desenvolvido quando as derivadas da função objetivo não estão disponíveis. Com este tipo de formulação os cálculos referentes às equações de fluxo em meio poroso do reservatório podem ser realizados por programas comerciais. Estes programas são considerados “caixas pretas”, pois não permitem qualquer alteração em sua formulação numérica. O processo de otimização será executado utilizando o método por aproximação seqüencial (SAO - *Sequential Approximate Optimization*) (Giunta e Eldred, 2000), juntamente com modelos substitutos locais (Guinta, 2002; Forrester et al, 2008; Afonso et al, 2008) e algoritmos de otimização não linear (Nocedal e Wright, 1999).

As incertezas geológicas relacionadas às propriedades petrofísicas, tais como permeabilidades serão consideradas. Para isto, o sistema computacional desenvolvido permite o desenvolvimento de simulações de propagação de incertezas. Com objetivo de reduzir o custo computacional na etapa de propagação de incertezas, as metodologias de expansão em caos polinomial e colocação estocástica serão utilizadas para modelar as saídas do processo estocástico (Xiu e Karniads, 2003; Eldred e Webster, 2008), juntamente com a expansão de Karhunen-Loeve (K-L) que será utilizada para representar as entradas. (Tatang, 1995; Huang et al, 2001; Sarma et al, 2008). A utilização da expansão de Karhunen-Loeve diretamente requer um alto custo computacional, para minimizar este problema é utilizada a técnica de análise dos componentes principais utilizando a matriz núcleo (KPCA - *Kernel Principal Component Analysis*). Esta metodologia quando aplicada na forma linear somente preserva os momentos de primeira e segunda ordem do campo estocástico, sendo necessária a utilização da metodologia KPCA não linear para representar os momentos de ordem maior que dois. A expansão de K-L na forma de KPCA linear será utilizada em problemas de propagação de incertezas e otimização considerando incertezas.

Outro objetivo deste trabalho é a realização de ajuste de histórico, neste caso as variáveis de projeto são relacionadas ao campo de permeabilidades do reservatório, portanto, a expansão de K-L também será utilizada para representar este campo. As metodologias KPCA linear e KPCA não linear serão utilizadas para realização de ajuste de histórico.

Os programas computacionais desenvolvidos serão todos implementados em Octave (GNU Octave, 2010), que é uma linguagem compatível com o Matlab (Mathworks, 2001). O sistema operacional utilizado será o Linux. O sistema computacional Dakota (Eldred, 2010) será utilizado, sendo possível aproveitar várias rotinas de otimização, modelos substitutos e métodos de amostragem disponíveis no sistema. O simulador comercial de reservatórios escolhido para o desenvolvimento da pesquisa foi o Imex (CMG, 2006).

1.4 Definição do Problema de Otimização das Alocações Dinâmicas das Vazões

O problema de otimização em reservatórios de petróleo a ser estudado neste trabalho é um caso de otimização não-linear, com restrições lineares e não-lineares. Serão consideradas as incertezas referentes ao campo de permeabilidades. A declaração formal do problema é apresentada abaixo:

$$\text{Maximize} = f(x_{p,t}, u) \quad (1.1)$$

Sujeito a:

$$\sum_{p \in P} x_{p,t} = 1, \quad t = 1 \dots n_t \quad (1.2)$$

$$\sum_{p \in I} x_{p,t} = 1, \quad t = 1 \dots n_t$$

$$x_{p,t}^l \leq x_{p,t} \leq x_{p,t}^u \quad (1.3)$$

Onde:

f é a função objetivo;

$x_{p,t}$ representa as variáveis de controle do problema no poço p , no intervalo de tempo t ;

u representa as variáveis de estado do problema;

$x_{p,t}^l$ e $x_{p,t}^u$ representam os limites superiores e inferiores das variáveis de controle. Onde P é o conjunto de poços produtores e I o conjunto de poços injetores, e n_t é o número total de intervalos de tempo de operação.

A função objetivo escolhida neste trabalho foi o valor presente líquido (VPL) do fluxo de caixa da operação do campo, apresentada com a correspondente equação (Oliveira, 2006):

$$VPL = f(x_{p,t}, u) = \sum_{\tau=0}^T \left[\frac{1}{(1+d)^\tau} F_\tau(x_{p,t}, u) \right] \quad (1.4)$$

Onde d é a taxa de desconto, T é o período de concessão e F_t é fluxo de caixa no tempo \mathcal{T} , que representa a receita do óleo menos o custo da injeção e produção de água.

As variáveis de controle são as vazões nos poços, através do rateio pela capacidade total do grupo de poços em cada intervalo de tempo. As variáveis de controle são definidas com a seguinte fórmula:

$$x_{p,t} = \frac{q_{p,t}}{Q_{l,max}}, p \in P \quad ; x_{p,t} = \frac{q_{p,t}}{Q_{Inj,max}}, p \in I \quad (1.5)$$

Onde $q_{p,t}$ é a vazão do poço p no intervalo de tempo t , $Q_{l,max}$ é a vazão máxima de produção de líquidos (óleo e água) permitida e $Q_{Inj,max}$ é a vazão máxima de injeção permitida na plataforma.

As variáveis de estado \mathbf{u} são os parâmetros que não podem ser controlados e podem possuir incerteza, como as propriedades dos fluidos, das rochas, de interação rocha-fluido, localização dos poços, além dos parâmetros econômicos (custos, cotação do dólar). Como já comentado, a única propriedade com incerteza considerada neste trabalho será o campo de permeabilidades do reservatório. As restrições serão os limites das vazões de produção e injeção nos poços.

1.5 Definição do Problema de Ajuste de Histórico

Neste trabalho o ajuste de histórico será realizado no campo de permeabilidades e a função objetivo envolve as produções de óleo acumuladas nos poços, que claramente dependem do campo de permeabilidades, sendo estas as variáveis de projeto. A formulação do problema é apresentada nas Equações 1.6 e 1.7.

$$\min_{\mathbf{m}} \left[\sum_{n=0}^{N-1} L^n(x^{n+1}, u^n, \mathbf{m}(\xi)) \right] \forall n \in (0, \dots, N-1)$$

Sujeito a:

$$\begin{aligned} g^n(x^{n+1}, x^n, u^n, \mathbf{m}(\xi)) &= 0 \quad \forall n \in (0, \dots, N-1) \\ x^0 &= x_0 \quad (\text{Condições iniciais}) \\ \mathbf{m} &\in \text{Realizações do campo de permeabilidades} \end{aligned} \quad (1.6)$$

Onde:

$$L^n(x^{n+1}, u^n, \mathbf{m}) = \sum_{i=1}^{N_w} \{f_i(x^{n+1}, u^n, \mathbf{m}) - d_{obs_i}^n\}^2 \quad (1.7)$$

Os campos de permeabilidade \mathbf{m} são parametrizados utilizando a expansão de K-L, logo podem ser representado pelo vetor ξ . As variáveis de estado (pressão, saturação, etc.) são representadas por \mathbf{x} e as variáveis de controle (vazões nos poços, pressão de fundo de poço, etc.) por \mathbf{u} e n é o índice do passo de tempo. A produção acumulada de óleo no tempo no poço i é representada por f_i e $d_{obs_i}^n$ é a produção acumulada de óleo observada no tempo n e no poço i .

1.6 Contribuições do Trabalho

Esta pesquisa tem como base os trabalhos desenvolvidos por Oliveira (2006) e Sarma (2006). O problema de gerenciamento de reservatório proposto neste trabalho é o mesmo apresentado por Oliveira, a diferença é que incertezas geológicas são consideradas. Neste trabalho as metodologias desenvolvidas também são aplicadas a problemas de ajuste de histórico, este tipo de problema não foi trado por Oliveira.

Sarma desenvolveu um sistema integrado de otimização, propagação de incertezas e ajuste de histórico. Este tipo de sistema é conhecido como ciclo fechado. As metodologias de propagação de incertezas (expansão de Karhunen-Loeve e expansão em caos polinomial) utilizadas nesta pesquisa foram apresentadas no trabalho de Sarma. Com relação à estratégia de otimização, Sarma desenvolveu uma metodologia na qual exige

acesso às equações do simulador de reservatório para obtenção das derivadas. Neste trabalho a estratégia de otimização (camadas e aninhamento, SAO) utilizada não precisa do acesso as equações do simulador para obtenção das derivadas, pois as mesmas são calculadas em modelos substitutos locais (Krigagem). Nesta metodologia as derivadas são obtidas com baixo custo computacional, além de permitir a utilização de simuladores comerciais de reservatório, também conhecidos como “*caixas-pretas*”.

1.7 Organização do Trabalho

Este trabalho foi organizado em sete capítulos. O capítulo introdutório apresenta as motivações que levaram ao desenvolvimento desta tese, que são apresentadas em dois grupos: econômicas e tecnológicas. Neste capítulo inicial também são apresentados os objetivos da pesquisa e as definições do problema. Os estudos de caso desenvolvidos em cada capítulo são aplicações em problemas de reservatório sob injeção de água ou gás.

O capítulo 2 apresenta uma revisão bibliográfica das principais áreas envolvidas neste trabalho: otimização da produção de óleo e gás, metodologias de propagação de incerteza e técnicas de ajuste de histórico.

No capítulo 3, os modelos substitutos são estudados e investigados. Nesta pesquisa foram estudadas as seguintes metodologias para geração de modelos substitutos: Krigagem, Processo Gaussiano e MARS. Para geração dos modelos substitutos é necessário definir o método de amostragem a ser utilizado. Também neste capítulo foram pesquisados três diferentes métodos de amostragem: Quase Monte Carlo (QMC), Hipercubo Latino (LHS), e Tesselação de Voronoi (CVT). Os resultados de diferentes combinações entre modelos substitutos e métodos de amostragem são apresentados.

As metodologias para o desenvolvimento da etapa de propagação de incertezas são apresentadas no capítulo 4. As incertezas são introduzidas através do campo de permeabilidades do reservatório. A expansão de Karhunen-Loeve é apresentada na sua forma linear e não linear. Também são apresentadas as metodologias de expansão em caos polinomial e colocação estocástica.

No capítulo 5 é realizada a etapa de otimização considerando incertezas, as metodologias discutidas nos capítulos 3 e 4 são utilizadas. Nesta etapa do trabalho, é possível perceber a importância de considerar a incerteza em estudos de otimização da produção de óleo.

O capítulo 6 é direcionado à realização de estudos sobre ajuste de histórico. As metodologias de modelos substitutos, propagação de incerteza, e otimização desenvolvidas e apresentadas nos capítulos anteriores são utilizadas em problemas de reservatório de petróleo.

O capítulo 7 tem como objetivo apresentar as conclusões da pesquisa, como também propor recomendações e novos desafios para trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

2.1 Otimização na Produção de Petróleo

A busca por condições ótimas é um dos maiores desafios no campo da engenharia de petróleo, principalmente quando relacionada à produção de óleo e gás, visto que esta área situa-se diretamente ligada à lucratividade deste setor industrial. De acordo com Sarma (Sarma, 2006), a otimização da produção está relacionada com a maximização do desempenho do reservatório, através da realização de um gerenciamento ótimo e tomando as melhores decisões de acordo com o objetivo proposto. Em um contexto mais amplo, segundo Chong (Chong e Zak, 2001), um problema de otimização pode ser visto como um problema de decisão, onde é necessário encontrar a melhor escolha entre as várias possíveis.

Considerando a importância de utilizar técnicas de otimização na produção de petróleo, várias metodologias vêm sendo utilizadas principalmente a partir dos anos 50. Os métodos de otimização são de inestimável importância, não apenas no âmbito da engenharia de petróleo, como também nos vários setores da engenharia, tais como automotiva, aeroespacial, mecânica, estrutural, fabricação, naval e outras. Como era de esperar estes métodos possuem uma extensa variedade de metodologias (Rao, 2009; Arora, 1989; Nocedal e Wright, 1999), sendo importante ainda ressaltar que esta é uma área de intensa pesquisa e novas metodologias surgem anualmente.

Os algoritmos de otimização de uma maneira ampla podem ser classificados em duas categorias: Algoritmos Estocásticos, como os Algoritmos Genéticos (Goldberg, 1989) e Recozimento Simulado (Kirpartric et al, 1983), e os Algoritmos de Programação Matemática como o Máxima Declividade e Quasi-Newton (Chong e Zak, 2001; Rao, 2009; Arora, 1989; Nocedal e Wright, 1999). As categorias citadas possuem particularidades, ou seja, vantagens e desvantagens. Os algoritmos estocásticos implicam em um alto custo computacional, pois são necessárias várias avaliações da função objetivo, além de não garantir a maximização ou minimização da função objetivo. A segunda categoria é geralmente mais eficiente, exige menos avaliações da função objetivo e garante redução da função objetivo a cada iteração, mas somente atinge um mínimo local em problemas não convexos (Gill et al, 1982).

Na área da otimização da produção de petróleo, a pesquisa e desenvolvimento pode ser agrupada basicamente nas seguintes áreas: a operação dos campos de petróleo, relacionada aos equipamentos e instalações de produção e de poços, e o desenvolvimento de campos de petróleo, direcionado a quantidade e distribuição de poços de desenvolvimento (não exploratórios). A última área diz respeito ao gerenciamento de campos de petróleo através da alocação dinâmica das vazões de produção e injeção (Oliveira, 2006). Este trabalho está inserido no contexto da última área mencionada.

Estudos de otimização em reservatórios de petróleo no contexto de gerenciamento de campos foram iniciados por volta dos anos 50. Aronofosky e Lee (1958) utilizaram metodologias de programação linear para otimizar alocações de vazões de óleo nos poços produtores. Neste estudo o reservatório é monofásico e homogêneo, sendo modelado como sistema infinito com fluxo radial sujeito ao mecanismo de produção por influxo de água (Rosa et al, 2006).

Attra et al (1961) desenvolveram um modelo baseado em programação linear para maximizar o fluxo de óleo em reservatórios sob injeção de gás, sujeitos a várias restrições de produção. Huppler (1974) desenvolveu um modelo baseado em programação dinâmica para otimização de reservatórios de gás. Em seguida, Kuller e Cummings (1974) desenvolveram um modelo para otimizar a produção e investimentos em reservatórios de gás.

Por volta de 1965, conceitos da teoria do controle ótimo começaram a ser introduzidos em problemas de otimização de reservatórios. Neste contexto pode ser destaca-

do o trabalho de Rowam e Warren (1967), que demonstraram como formular um problema de gerenciamento de reservatório em termos da teoria do controle ótimo.

Alguns pesquisadores perceberam a possibilidade de acoplar os métodos numéricos de otimização a simuladores de reservatório de petróleo. Wattenberg (1970), desenvolveu um modelo de programação linear que trabalha acoplado com um simulador de reservatórios, desenvolvido em diferenças finitas, para otimizar a produção de reservatórios de gás. Mais adiante, See e Horne (1983) também desenvolveram uma metodologia de otimização baseada em programação linear e utilizando simuladores de reservatório, nesta abordagem um modelo de reservatório linear é construído e calibrado utilizando técnicas de regressão a partir de um conjunto de experimentos. MacFarland et al (1984) utilizaram técnicas de otimização não linear tendo como objetivo maximizar o lucro na produção de petróleo.

Pan e Horne (1998) investigaram a utilização de métodos de interpolação multivariada, tais como Krigagem e Mínimos Quadrados para gerar novas realizações a partir de um número limitado de simulações. O objetivo era prever estratégias ótimas para a produção de reservatórios sob injeção de água. Um planejamento de experimentos com distribuição uniforme é utilizado, a partir de onde os modelos substitutos são criados.

A utilização de métodos adjuntos foi proposta no trabalho de Fathi e Ramirez (1985), nesta pesquisa a metodologia de controle ótimo com método adjunto foi aplicada em problemas de injeção de polímeros. É importante lembrar que nos casos dos métodos adjuntos e metodologia de controle ótimo, a quantidade de simulações para calcular o gradiente numericamente não aumenta com relação ao aumento do número de variáveis de controle. Zakirov et al (1996) desenvolveram um método adjunto para um problema de otimização da produção de gás. Métodos adjuntos aplicados a problemas de injeção de água foram desenvolvidos por Asheim (1988), Virnovski (1991), Sudaryanto e Yortsos (2001) e recentemente nos trabalhos de Brouwer e Jansen (2002), como também no trabalho de Sarma et al (2004).

Harting et al (1998) utilizaram Algoritmos Genéticos (Goldberg, 1989) em problemas de otimização da produção de reservatórios de óleo e gás, neste trabalho foram feitos estudos comparativos com outros métodos, tais como Recozimento Simulado e Programação Quadrática Sequencial.

Uma metodologia combinando as técnicas de árvore de derivação, superfície de resposta e técnica de Monte Carlo foi desenvolvida por Floris e Peersmann (2000) no problema de tomada de decisão no desenvolvimento de um campo real considerando incertezas.

O Algoritmo de Busca Dispersa – Scatter Search (Glover, 2000) foi utilizado por Cullick et al (2003). Neste trabalho foi desenvolvido um estudo de otimização referente à estratégia de produção relacionada a múltiplos reservatórios, considerando incertezas e realizando análise de risco. O método de Monte Carlo foi utilizado quando a incerteza era considerada.

Oliveira (Oliveira, 2006) realizou um estudo de otimização com a utilização de algoritmos que não utilizam informações das derivadas no seu processo de busca da solução. Neste trabalho a função objetivo foi o VPL (Valor Presente Líquido), e os reservatórios estudados estavam sob injeção de água. Os algoritmos utilizados foram: Nelder e Mead (Simplex), Busca Direta em Padrões (Pattern Search), Derivative Free Optimization (DFO) e Genético. Oliveira desenvolveu seu trabalho sem considerar incertezas.

Em 2005, Sarma apresentou uma metodologia relacionada ao gerenciamento de reservatórios em tempo real. Neste trabalho foi desenvolvido um sistema integrado envolvendo otimização, atualização de modelo e propagação de incertezas, as metodologias desenvolvidas também foram aplicadas a problemas de ajuste de histórico. Este tipo de metodologia é conhecido como “*Closed-Loop approach*” (Sarma, 2006). A etapa de otimização foi baseada em um método adjunto, este modelo fornece as derivadas da função objetivo com relação às variáveis de controle, que são utilizadas em algoritmos padrões de otimização com objetivo de determinar as variáveis de controle ótimas. Na etapa de atualização do modelo, a teoria de inversão Bayesiana (Tarantola, 2005) é utilizada em conjunto com a expansão de Karhunen-Loeve (Tatang, 1995; Huang et al, 2001; Sarma, 2006). Com relação à etapa de propagação de incertezas, Sarma utilizou a expansão em caos polinomial juntamente com a expansão em Karhunen-Loeve.

Com a utilização em larga escala dos simuladores de fluxo comerciais (CMG, 2006; Geoquest, 2005), a obtenção das derivadas da função objetivo torna-se impossível caso não exista acesso ao código do programa, e o mesmo não forneça as derivadas. O custo de obter as derivadas por diferenças finitas neste tipo de problema é muito

alto. É evidente a necessidade de pesquisa no desenvolvimento de alternativas para solução de problemas de otimização de reservatórios quando não se tem acesso ao código fonte do simulador. Este obstáculo foi uma importante motivação para o desenvolvimento deste trabalho.

2.2 A Incerteza na Caracterização do Reservatório

A modelagem computacional considerando incertezas vem se tornando indispensável nos mais diversos campos da engenharia. Na maioria das vezes os problemas são resolvidos baseando-se em simulações determinísticas, levando em muitos casos a decisões incorretas e conseqüentemente prejuízo econômico. De acordo com Urroz (2005), um sistema determinístico é conhecido como um sistema onde os valores de entrada e as saída são conhecidos e determinados com exatidão. Em contrapartida quando existe incerteza nos parâmetros de entrada e nas respostas do sistema, o sistema é conhecido como estocástico. Costa (2006) define que a incerteza é a grandeza associada à falta de conhecimento de atributos, cujos valores não se pode obter de maneira precisa ou para o qual existe dúvida. No caso da engenharia de reservatórios os atributos podem ser geológicos, tecnológicos ou econômicos. Considerando que nos reservatórios de petróleo, as incertezas estão presentes em várias formas, torna-se indispensável o desenvolvimento da modelagem estocástica do sistema.

As incertezas geológicas nos reservatórios estão relacionadas a propriedades da rocha, fluidos, volume de óleo na superfície, falhas geológicas, etc. Quanto às incertezas tecnológicas temos, por exemplo, as dúvidas sobre o avanço das tecnologias de exploração e produção com o passar do tempo. Com relação às incertezas econômicas, temos o preço do barril de petróleo, inflação, cotação do dólar, etc. Neste trabalho a pesquisa foi direcionada à incerteza geológica, com a consideração do campo de permeabilidades como grandeza incerta.

Em 1934, Hayward utilizou conceitos matemáticos de teoria das probabilidades para cálculo de preços ligados a negócios na indústria de petróleo (Hayward, 1934). Em seguida a teoria das probabilidades, árvores de decisão e simulações de Monte Carlo

foram aplicadas em gerenciamento de reservatórios de petróleo (Grayson, 1960; Newendorp, 1975; Smith, 1970).

A utilização de métodos tradicionais como simulações de Monte Carlo e suas variantes, como Hypercubo Latino, em problemas de propagação de incertezas são metodologias normalmente implementadas. Entretanto, estas técnicas são computacionalmente caras, e na maioria dos casos impraticáveis em modelos de simulação de reservatórios (Xiu e Karniadakis, 2003).

O método de sensibilidades (Hills e Trucano, 1999) é uma alternativa às simulações de Monte Carlo, implica em menor custo computacional, mas é menos robusto e depende fortemente de algumas considerações na modelagem. Outra metodologia utilizada é o método da perturbação (Xiu e Karniadakis, 2003), onde todas as quantidades estocásticas são expandidas em torno de suas médias via séries de Taylor.

Ghanem e Spanos (1991) foram os pioneiros na utilização de uma metodologia utilizando o método dos elementos finitos. Esta metodologia é conhecida como método dos elementos finitos estocásticos. A vantagem deste método é a eficiência computacional, entretanto requer acesso as equações matemáticas do modelo, ou seja, não permite o uso de simuladores como “caixas pretas”.

Sarma et al (2008) apresentaram uma metodologia que envolve a aplicação da expansão de Karhunen-Loeve (K-L) em estudos de propagação de incerteza e ajuste de histórico em reservatórios de petróleo. Nesta metodologia campos de permeabilidade são parametrizados honrando suas características geológicas. Neste mesmo trabalho as saídas do processo estocástico são representadas por expansão em caos polinomial.

2.3 A Evolução do Processo de Ajuste de Histórico

Conforme definição de Moura Filho (2006), o ajuste de histórico de produção é um método que visa calibrar os modelos de simulação a partir de dados simulados e observados, através da minimização matemática de uma função objetivo, que representa a qualidade do ajuste, de modo a reproduzir o comportamento passado, e baseado nele elaborar estratégias de gerenciamento e planos futuros de exploração.

Frequentemente na indústria é utilizada a metodologia de tentativa e erro, que evidentemente possui várias desvantagens, tais como encontrar soluções distantes do ótimo. A outra forma de realizar ajuste é conhecida como ajuste automatizado, este é um campo de pesquisa que vem se tornando cada vez mais importante, trabalhos como os de Maschio e Schiozer (2003), Brouwer et al (2004) e Sarma et al (2007) mostram importantes alternativas e avanços.

Segundo Leitão (1997), apesar de nas décadas de 70 e 80, inúmeros trabalhos envolvendo a automatização do processo de ajuste de histórico tenham sido propostos, o uso desta metodologia não se difundiu como esperado. Os motivos que levaram a esta dificuldade em utilizar o processo automático de ajuste são: 1) multiplicidade de soluções, com os parâmetros otimizados tendo forte influência das aproximações iniciais; 2) As respostas dos modelos são, quase sempre, extremamente não-lineares com relação aos parâmetros, o que dificulta ou torna lenta a convergência dos métodos de otimização; 3) oscilações da função objetivo, que levam a mínimos locais como solução do problema; 4) alto custo computacional do processo.

Possivelmente os primeiros trabalhos relacionados a processos de ajuste de histórico automatizado foram apresentados por Jacquard (1964); Jacquard e Jain (1965). Estes trabalhos foram baseados em modelos de reservatórios monofásicos uni e bidimensional. Outros trabalhos que tiveram como base as pesquisas de Jacquard foram desenvolvidos como o trabalho de Hans (1966) que utilizou o método de regressão não-linear de Gauss-Newton no processo de ajuste.

Um dos primeiros trabalhos a utilizar a teoria do controle ótimo em problemas de ajuste de histórico foi o de Chavent et al (1973). Estudos em modelos de reservatórios monofásicos foram desenvolvidos por Chavent et al, o objetivo era minimizar a diferença entre as pressões calculadas e observadas. Os parâmetros de ajustes eram o produto permeabilidade-espessura e porosidade-espessura. O algoritmo de Máxima Derivada foi usado no processo de otimização.

Wasserman et al (1974), entre outros, utilizou a teoria do controle ótimo em problemas de ajuste de histórico, considerando modelos de simuladores multi-fásicos. Chavent e Cohen (1980) utilizaram a teoria do controle ótimo para estimar curvas de permeabilidade relativa e funções de pressão capilar. Os fluidos foram considerados incompressíveis. Fasanino et al (1986), desenvolveram estudos de ajuste de histórico em

reservatórios de gás 2D utilizando método adjunto em combinação com informações geoestatísticas.

Os métodos Quasi-Newton foram aplicados em problemas de ajuste de histórico por Yang et al (1987). Li et al (2001) realizaram estudos de ajuste de histórico em problemas tridimensionais, também consideraram três fases no fluxo dos fluidos. O objetivo era minimizar a diferença entre as pressões de fundo de poço calculadas e observadas.

Brouwer (2004) no processo de ajuste de histórico utilizou métodos adjuntos para otimização e filtros de Kalman para atualização dos modelos. Aitokhuehi e Durlowsky (2005) utilizaram algoritmos de gradientes conjugados com gradientes numéricos na etapa de otimização e o método da perturbação probabilística para atualização do modelo.

Sarma et al (2008) desenvolveram uma metodologia para problemas de atualização de modelo utilizando a teoria Bayesiana inversa, neste trabalho o campo de permeabilidades foi parametrizado eficientemente utilizando a expansão de Karhunen Loeve (K-L).

Capítulo 3

Modelos Substitutos

3.1 Introdução

A necessidade de tomar decisões em intervalos de tempo cada vez menor, nos mais variados campos da engenharia, associado a uma série de limitações, tais como simulações de alto custo computacional, vêm proporcionado uma enorme quantidade de investimentos no desenvolvimento de novas ferramentas computacionais. Os modelos substitutos (Guinta 2002; Forrester et al, 2008; Afonso et al, 2008) estão inseridos neste contexto, principalmente quando utilizados em problemas de otimização, como é o caso deste trabalho.

Na engenharia de reservatórios de petróleo existem muitos parâmetros que podem afetar a produção de hidrocarbonetos, tais como: propriedades das rochas, propriedades dos fluidos, posição dos poços e alocação dinâmica das vazões de produção e injeção. O desenvolvimento de estudos de otimização na produção de óleo e gás requer a avaliação de simulações com diferentes combinações de parâmetros. Entretanto, executar uma única simulação pode ter um elevado custo computacional. A utilização de modelos substitutos torna possível reduzir o custo computacional das simulações, apesar de ainda ser necessária a realização de um determinado número de simulações (amostras) no modelo de alta fidelidade.

No desenvolvimento de estudos de otimização, dois problemas estão frequentemente presentes. O primeiro está relacionado ao tempo de execução das simulações. O outro problema é a falta de informações sobre as derivadas nos problemas complexos.

Estes dois problemas citados são perfeitamente aplicados a área de simulação e gerenciamento de reservatórios de petróleo, que é a área de atuação deste trabalho.

A idéia principal do modelo substituto é construir um modelo aproximado do modelo de alta fidelidade. Uma vez construído o modelo substituto o resultado de uma simulação é obtido com um custo computacional muito mais baixo que seria com o modelo de alta fidelidade, adicionalmente o modelo substituto também pode fornecer informações aproximadas das derivadas.

Os modelos substitutos estão divididos em três principais categorias, são elas: interpolação de dados, modelos de múltipla fidelidade e modelos de ordem reduzida (Forrester et al, 2008; Keane e Nair, 2005). Neste trabalho os modelos substitutos utilizados foram obtidos com interpolação de dados. Na atualidade, existem vários tipos de modelos substitutos por interpolação de dados que podem ser aplicados, entre os principais estão: Modelos Polinomiais (Guinta e Watson, 1998), Kriging (Jones et al, 1998; Guinta e Watson, 1998; Van Beers e Kleijnen, 2004; Forrester et al, 2008), Redes Neurais (Gurney, 1997) e MARS (Friedman, 1991; Hastie et al, 2001).

Nos problemas de engenharia freqüentemente existe a necessidade de construir um modelo \hat{f} de baixo custo (substituto) substituindo um modelo de alto custo f . Formalizando matematicamente o problema, a metodologia é apresentada da seguinte forma: considerando $f(x)$ uma função contínua definida por um vetor contendo as variáveis de projeto x de ordem k , onde $x \in D \subset R^k$. D é definido como o espaço de projeto. Assumindo f contínua, através das amostras $x^{(i)}$ são obtidos os valores em f no modelo de alta fidelidade, esta operação é representada da seguinte forma:

$$\left\{ x^{(i)} \longrightarrow y^{(i)} = f \left(x^{(i)} \right) \mid i = 1, \dots, n \right\} \quad (3.1)$$

Onde n é o número total de amostras. Utilizando as amostras $y^{(i)}$ é construído o modelo substituto \hat{f} utilizado para calcular o valor da função f para qualquer valor $x \in D$.

Um dos principais obstáculos relacionado à resolução de um problema de otimização na engenharia é o alto número de variáveis de projeto. A maneira mais simplifi-

cada de gerar modelos substitutos para resolver problemas de otimização é utilizando a metodologia de experimento completo. Nesta metodologia a função objetivo é avaliada uma vez para cada combinação possível entre as variáveis de projeto dentro do espaço de projeto. Considerando um problema com dimensão k e n possíveis localizações das variáveis de projeto, para desenvolver um estudo de experimento completo seriam necessárias n^k avaliações da função objetivo. Para se ter uma idéia, em um problema com dimensão k igual a oito, e dez possíveis localizações para cada variável de projeto, onde cada avaliação da função objetivo dura uma hora, o tempo total requerido para a realização de um experimento completo seria de 10^8 , ou seja, de 11 416 anos. É evidente que a utilização da metodologia de experimento completo é completamente inviável para o tipo de problema a ser tratado neste trabalho, sendo, portanto necessário a utilização de métodos de amostragem viáveis para geração de modelos substitutos. Alguns métodos de amostragem foram testados e serão apresentados neste capítulo.

3.2 Modelos Substitutos Obtidos por Interpolação de Dados

O processo de desenvolvimento de um modelo substituto por interpolação envolve várias etapas, a primeira etapa é a geração de amostras. Várias metodologias estão disponíveis para geração de amostras, tais como Quasi-Monte Carlo (QMC), Hipercubo latino (LHS - *Latin Hypercube Sampling*) e método da tesselação de Voronoi (CVT - *Centroidal Voronoi Tessellation*) (Giunta, 2002; Giunta et al, 2003). Com as amostras disponíveis, o passo seguinte é o desenvolvimento de um processo de estimação de parâmetros, com objetivo de criar o modelo substituto. Nesta etapa a metodologia mais utilizada é a estimativa de Máxima Verossimilhança (Meyer, 2000).

Uma vez criado o modelo, a etapa posterior é a realização de testes para verificar se o modelo é representativo com relação ao modelo de alta fidelidade. Várias técnicas de verificação encontram-se disponíveis na literatura, dentre elas o RMSE (Afonso et al, 2008) que foi utilizado neste trabalho. Geralmente os testes de verificação de modelo utilizando RMSE (*Root Mean Square Error*) mostram que quanto maior o número de amostras maior precisão terá o modelo substituto. Evidentemente a partir de certo nú-

mero de amostras a qualidade de modelo não varia mais, neste caso é dito que o modelo está saturado com relação ao número de amostras.

O cálculo do RMSE é realizado de acordo com a equação a seguir:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (f_i - \hat{f}_i)^2}{N}} \quad (3.2)$$

Onde f_i são valores do modelo de alta fidelidade e \hat{f}_i são valores do modelo substituto nas amostras i . Sendo N o número total de amostras.

3.3 Métodos de Amostragem

Projeto de Experimentos (DOE - *Design of Experiments*) é um conjunto de técnicas de amostragem para gerar um conjunto de pontos num determinado espaço de projeto (Giunta et al, 2003; Keane e Nair, 2005). Neste trabalho serão usados projetos de experimentos modernos. O termo “moderno” refere-se às técnicas desenvolvidas para uso com simulações computacionais determinísticas. O outro tipo de DOE são os clássicos, usados em experimentos de laboratório e campo, que apresentam erros aleatórios.

A característica principal do DOE moderno aplicado em experimentos computacionais determinísticos é que não existe erro aleatório, ou seja, se uma simulação computacional é executada duas vezes teremos a geração do mesmo conjunto de amostras. Outra característica importante é que a tendência da resposta não é conhecida, por exemplo, não se sabe se a resposta é cúbica ou quadrática.

Considerando a geração de um pequeno número de amostras por um método de geração uniforme aleatório não correlacionado, tipo Monte Carlo (Halton, 1970; Oliver et al, 2008), tem-se possivelmente a geração de amostras mal distribuídas no domínio e com a geração de vários vazios. Um exemplo com geração de Monte Carlo pode ser

visualizado na Figura 3.1, onde temos a geração de uma amostra de 100 pontos num espaço bidimensional, e cada variável do espaço encontra-se no intervalo de $[0, 1]$.

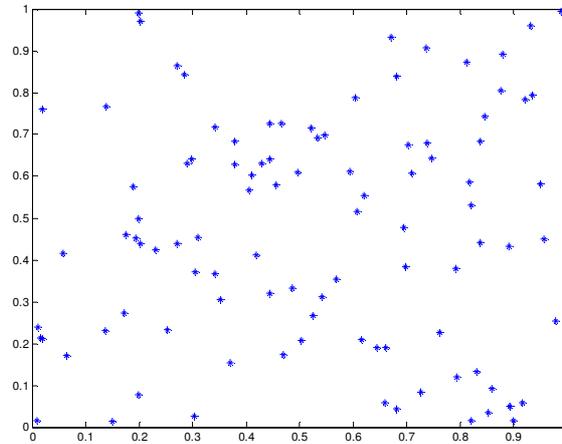


Figura 3.1: Amostragem gerada pelo método de Monte Carlo.

Com o objetivo de gerar o mesmo número de amostras, com distribuição mais uniforme, os tipos de DOE modernos utilizados neste trabalho são: Quasi-Monte Carlo (QMC), método da tesselação de Voronoi (CVT) e Hipercubo Latino (LHS). Todo o estudo de geração de amostras será desenvolvido utilizando os programas computacionais Dakota (Eldred, 2010) e Octave (GNU Octave, 2010).

3.3.1 Método de Quasi-Monte Carlo (QMC)

O método de Quasi-Monte Carlo (Giunta et al, 2003; Kocis e Whiten, 1997) é puramente determinístico e gera amostragens com uma melhor distribuição do que seria obtido com um método de geração aleatória, como Monte Carlo. Este método é caracterizado por usar seqüências de baixa discrepância, onde discrepância é a medida quantitativa de quanto à distribuição de amostras desvia de uma distribuição uniforme ideal. Um exemplo de seqüência de baixa discrepância é a seqüência de Van de Corput (Kocis e Whiten, 1997).

A Figura 3.2 mostra uma amostragem usando o método Quasi-Monte Carlo, onde temos a geração de uma amostra de 100 pontos num espaço bidimensional, cada variável do espaço está no intervalo de $[0, 1]$.

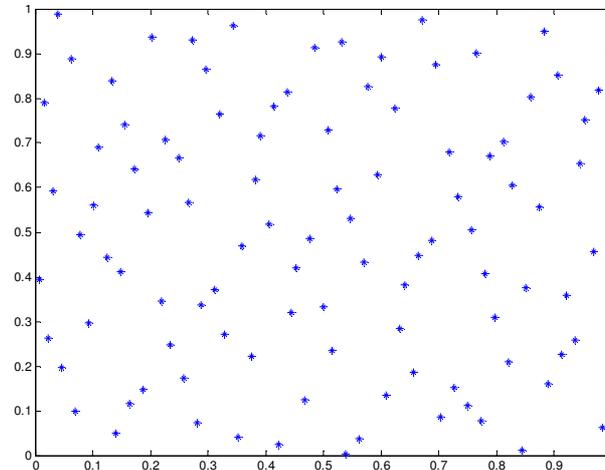


Figura 3.2: Amostragem gerada pelo método de Quasi-Monte Carlo.

3.3.2 Método da Tesselção de Voronoi (CVT)

Considerando um conjunto de pontos gerados aleatoriamente, o método da tesselação de Voronoi (CVT – *Centroidal Voronoi Tesselations*) é baseado na construção de mosaicos de Voronoi (Du et al, 1999). Na Figuras 3.3 a 3.5 temos exemplo de um conjunto de amostras gerados pelo método CVT. Este método pode ser usado na forma LCVT (*Latin Centroidal Voronoi Tesselations*). Neste caso, para todas as projeções unidimensionais das amostras, somente deve existir uma única projeção no intervalo particionado de cada variável. Está idéia será mostrada na próxima seção referente a método LHS.

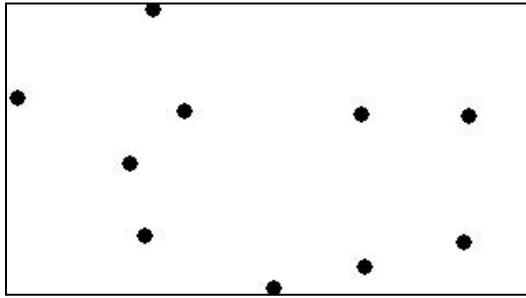


Figura 3.3: Conjunto inicial de pontos geradores.

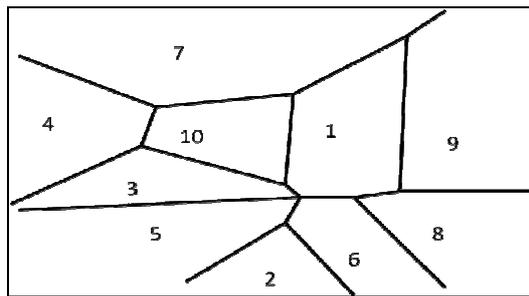


Figura 3.4: O método de tesselação de Voronoi para os pontos da Figura 3.3.

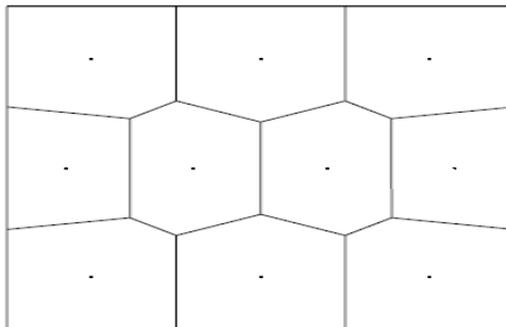


Figura 3.5: O método de tesselação de Voronoi (CVT) após atingir a condição final de uniformidade.

3.3.3 Hiper cubo Latino (LHS)

A idéia principal do Hiper cubo Latino (LHS - *Latin Hypercube Sampling*) consiste em dividir a faixa de valores de cada variável (X_j) em m intervalos com mesma probabilidade de incidência, sendo os pontos da amostragem gerados aleatoriamente em cada intervalo (Giunta et al, 2003).

Considerando n amostras com dimensão d , (x_1, x_2, \dots, x_d), e as faixas de valores de cada variável, teremos um total de n^d intervalos. Um exemplo de amostras escolhidas aleatoriamente num espaço de dimensão dois é mostrado na Figura 3.6.

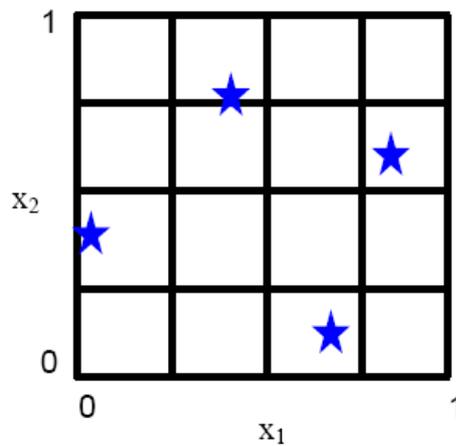


Figura 3.6: Amostragem gerada pelo método LHS num espaço bidimensional (Giunta et al, 2003).

As condições para geração das amostras são:

1. Somente uma amostra é escolhida dentro de cada área retangular (*Bin*).
2. Para todas as projeções unidimensionais das amostras, somente deve existir uma única projeção no intervalo particionado de cada variável.

3.4 Modelos Substitutos

Nesta etapa do trabalho três diferentes metodologias de modelos substitutos foram utilizadas: Krigagem, MARS e Processo Gaussiano. A seguir os métodos serão apresentados.

3.4.1 Krigagem

A idéia central da Krigagem (Jones et al, 1998; Guinta e Watson, 1998; Van Beers e Kleijnen , 2004; Forrester et al, 2008) é que os valores de resposta (pontos amostrais) possuem correlação espacial com os valores modelados pelo processo gaussiano. As principais vantagens do método são: a habilidade de acomodar dados em espaços irregulares, e a habilidade de modelar funções com vários picos e vales juntos com uma interpolação exata nos pontos amostrais. Neste método a função desconhecida a ser aproximada é dada por:

$$f(\mathbf{x}) = \sum_{j=1}^k \beta_j N_j(\mathbf{x}) + Z(\mathbf{x}) \quad (3.3)$$

Na equação acima, o primeiro termo é uma regressão dos dados com k regressores, e $Z(x)$ é o erro da função aleatória (geralmente é uma distribuição normal Gaussiana), com média zero, variância σ^2 , e covariância não nula.

O primeiro termo é responsável pelo modelo global ou pela tendência no espaço de projeto, enquanto $Z(x)$ é responsável por criar um desvio localizado no modelo global. Polinômios são geralmente usados para construir o termo $N_j(\mathbf{x})$.

A matriz de covariância dos erros da função nos pontos amostrais é dada por:

$$\text{cov}[Z(\mathbf{x}^i), Z(\mathbf{x}^j)] = \sigma^2 \mathbf{R}[\mathbf{R}(\mathbf{x}^i, \mathbf{x}^j)] \quad (3.4)$$

Onde \mathbf{R} é matriz de correlação $m \times m$ com valores unitários ao longo da diagonal principal, e $R(\mathbf{x}^i, \mathbf{x}^j)$ é a função de correlação entre dois dos m pontos amostrais. Diferentes formas de funções de correlação podem ser empregadas, tais como, exponencial, exponencial generalizada, Gaussiana, entre outras (Lophaven et al, 2002).

Neste trabalho é considerada a função de correlação Gaussiana com a seguinte forma:

$$R(\mathbf{x}^i, \mathbf{x}^j) = \exp\left(-\sum_{k=1}^{n_{dv}} \theta_k \left|\mathbf{x}_k^i - \mathbf{x}_k^j\right|^2\right) \quad (3.5)$$

Onde n_{dv} é o número total de variáveis, e θ_k são os parâmetros de correlação desconhecidos usados para aproximar o modelo.

A função $\hat{f}(\mathbf{x})$ é responsável por estimar os valores aproximados da função real (não conhecida), considerando o conhecimento apenas nos pontos amostrais. A função é da seguinte forma:

$$\hat{f}(\mathbf{x}) = E\left(f(\mathbf{x}) \mid f(\mathbf{x}^{(1)}), \dots, f(\mathbf{x}^{(m)})\right) \quad (3.6)$$

Analisando a função, é verificado que seu significado vem da estatística, que é o valor esperado de $f(\mathbf{x})$ condicionado aos valores de $f(\mathbf{x}^{(1)}), \dots, f(\mathbf{x}^{(m)})$. A medida do erro entre o modelo aproximado $\hat{f}(\mathbf{x})$ e o modelo $f(\mathbf{x})$ em todo espaço de projeto pode ser estimado utilizando o conceito de erro quadrático médio ou MSE (*Mean Squared Error*) onde:

$$\text{MSE} = E(\hat{f}(\mathbf{x}) - f(\mathbf{x}))^2 \quad (3.7)$$

A função estimadora $\hat{f}(\mathbf{x})$ de qualquer ponto no domínio de projeto pode ser obtida minimizando o MSE. Conhecendo $N(\mathbf{x}) = [N_1(\mathbf{x}), N_2(\mathbf{x}), \dots, N_k(\mathbf{x})]^T$ a função estimadora é:

$$\hat{f}(\mathbf{x}) = N(\mathbf{x})^T \hat{\boldsymbol{\beta}} + \mathbf{r}^t(\mathbf{x}) \mathbf{R}^{-1} (\mathbf{f}_s - \mathcal{N} \hat{\boldsymbol{\beta}}) \quad (3.8)$$

Onde $\hat{\boldsymbol{\beta}}$ é desconhecido, $\mathbf{f}_s = [f_1, \dots, f_m]^T$ são os valores reais nas amostras e \mathcal{N} é uma matriz $m \times k$ dada por:

$$\mathcal{N} = \begin{bmatrix} N_1(\mathbf{x}_1) \dots N_k(\mathbf{x}_1) \\ \vdots \\ N_1(\mathbf{x}_m) \dots N_k(\mathbf{x}_m) \end{bmatrix} \quad (3.9)$$

No caso particular da Krigagem ordinária, \mathcal{N} é um vetor coluna unitário de tamanho m . A equação acima requer o cálculo do vetor de correlação $\mathbf{r}(\mathbf{x})$, o qual correlaciona um valor aproximado x com os pontos amostrais m . O vetor tem a seguinte forma:

$$\mathbf{r}(\mathbf{x}) = \left[R(\mathbf{x}, \mathbf{x}^1), R(\mathbf{x}, \mathbf{x}^2), \dots, R(\mathbf{x}, \mathbf{x}^m) \right]^T \quad (3.10)$$

Os valores de $\hat{\boldsymbol{\beta}}$ e a variância estimada σ^2 são obtidos utilizando mínimos quadrados generalizados, logo os termos ficam com a seguinte forma:

$$\hat{\boldsymbol{\beta}} = (\mathcal{N}^T \mathbf{R}^{-1} \mathcal{N})^{-1} \mathcal{N}^T \mathbf{R}^{-1} \mathbf{f}_s \quad (3.11)$$

E a variância estimada fica:

$$\sigma^2 = \frac{(f_s - \mathcal{N}\hat{\beta})^T \mathbf{R}^{-1} (f_s - \mathcal{N}\hat{\beta})}{m} \quad (3.12)$$

Na equação 3.8, tanto \mathbf{r} como \mathbf{R} dependem do parâmetro desconhecido θ_k , que é encontrado maximizando a função máxima verossimilhança (Keane e Nair, 2005).

No Dakota (Eldred, 2010) existe uma metodologia para geração de modelos substitutos denominada Processo Gaussiano (GP). Esta técnica é muito similar a Krigagem, exceto a função de correlação que é dada por (Kennedy e Hagan, 2000):

$$R(\mathbf{x}^i, \mathbf{x}^j) = \exp \left(- \sum_{k=1}^{ndv} \theta_k (\mathbf{x}_k^{(i)} - \mathbf{x}_k^{(j)}) \right)^2 \quad (3.13)$$

3.4.2 MARS

MARS (*Multivariate Adaptive Regression Splines*) é um procedimento adaptativo para resolver problemas de regressão não paramétrica (Friedman, 1991; Hastie et al, 2001). Pode ser visto como uma generalização do método de regressão linear por etapas, onde a interpolação dos dados de entrada é realizada por Splines em diferentes intervalos.

O procedimento de adaptação do MARS é totalmente automatizado, onde os dados de entrada são separados por regiões com suas próprias linhas de regressão ou hiperplanos (amostras no espaço com mais de duas dimensões). O modelo para Splines de primeira ordem pode ser descrito através da seguinte forma:

$$f(X) = \beta_0 + \sum_{m=1}^M \beta_m h_m(X) \quad (3.14)$$

Onde $h_m(X)$ é uma expansão de uma base linear na forma $(x-t)_+$ e $(t-x)_+$. Onde:

$$(x-t)_+ = x-t, \text{ se } x > t \text{ ou } 0, \text{ qualquer outro caso,} \quad (3.15)$$

e

$$(t-x)_+ = t-x, \text{ se } x < t \text{ ou } 0, \text{ qualquer outro caso.} \quad (3.16)$$

Os coeficientes β_m são estimados por mínimos quadrados, isto é, por regressão linear padrão. As funções da base são lineares por partes, com nó no valor t (Figura 3.7).

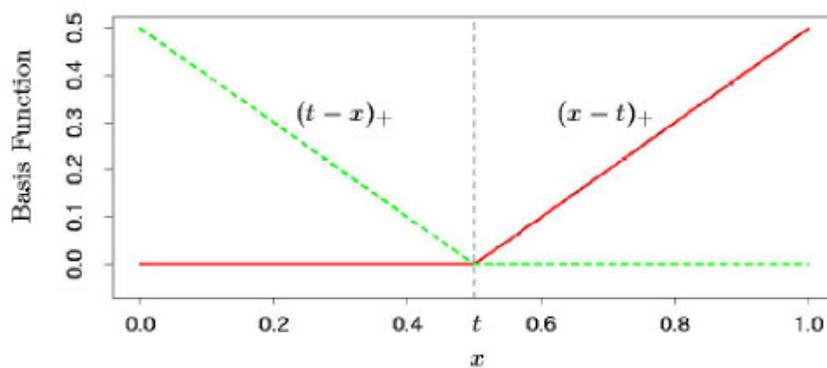


Figura 3.7: Funções da base utilizada no MARS (Hastie et al, 2001).

A idéia principal é formar pares refletidos para cada variável da amostra X_j com nó pertencendo ao conjunto de valores de entrada observados x_{ij} (valor referente a variável em questão). A base linear é composta das funções pertencentes ao conjunto C indicado abaixo:

$$C = \{(X_j - t), (t - X_j)\} \text{ onde } \begin{matrix} t \in \{x_{1j}, x_{2j}, \dots, x_{Nj}\} \\ j = 1, 2, \dots, p. \end{matrix} \quad (3.17)$$

Se todos os valores de entrada forem distintos, o conjunto C terá $2Np$ funções, onde N é a quantidade de amostras e p é a quantidade de variáveis da amostra. A função h inicial é $h_0(X)=1$ e todas as funções no conjunto C são candidatas a serem escolhidas na etapa seguinte, em cada estágio é considerado um novo par de funções da base.

Um exemplo do MARS aplicado a um caso de amostras no espaço bidimensional é mostrado na Figura 3.8.

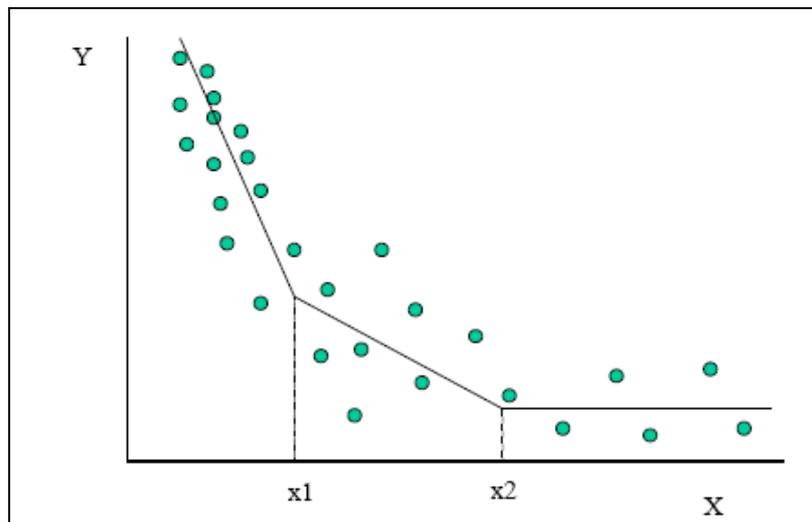


Figura 3.8: Aproximação no espaço bidimensional com aplicação do MARS (Briand et al, 2000).

No caso de amostras no espaço com mais de duas dimensões, as funções $h(X)$ são calculadas através de multiplicações das funções da base linear, um exemplo seria $h(X_1, X_2) = (X_1 - x_{51})_+ \cdot (x_{72} - X_2)_+$ como mostrado na Figura 3.9.

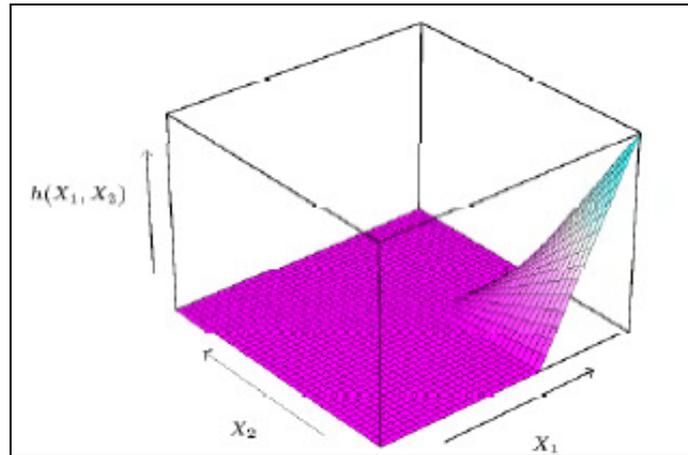


Figura 3.9: Função $h(X)$ para amostras no espaço tridimensional (Hastie et al, 2001).

Informações adicionais podem ser encontradas nos trabalhos em Hastie et al (2001) e Friedman (1999).

3.5 Estudo de Caso – Injeção de Água em Reservatório com 3 Poços

As metodologias de amostragem e modelos substitutos apresentadas nas seções anteriores foram aplicadas a um caso de reservatório de petróleo com injeção de água (Oliveira, 2006). O reservatório usado nos estudos possui dois poços produtores e um poço injetor, como também três regiões com permeabilidades constantes. Um esquema do reservatório é apresentado na Figura 3.10.

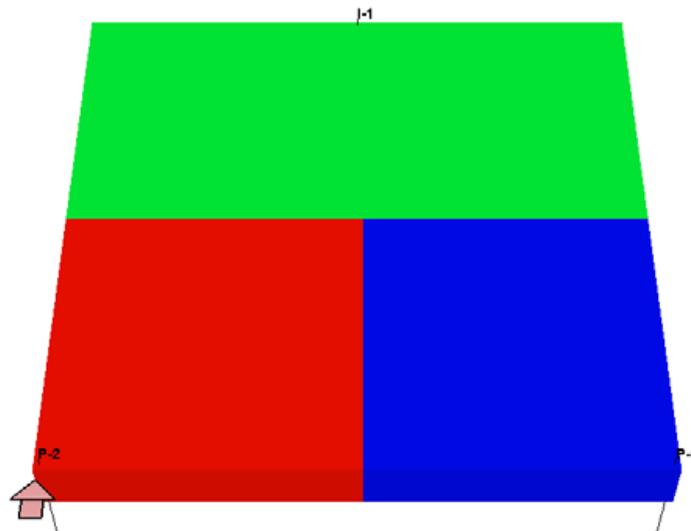


Figura 3.10: Esquema do reservatório, mostrando a localização dos poços e as regiões de permeabilidade horizontal (Oliveira, 2006).

O objetivo deste estudo de caso é descobrir quais das metodologias de DOE e modelos substitutos apresentadas, são mais adequadas a serem usadas no cálculo do valor presente líquido num determinado período de tempo. Diferentes casos de restrições nos poços foram estudados, tais como, corte de água (WC – *Water Cut*) e pressão de fundo de poço (BHP- *Bottom Hole Pressure*).

A vazão de injeção de água é fixada em 44 m³/dia e a soma das vazões nos poços produtores é fixada em 40 m³/dia. As variáveis de projeto são as porcentagens de alocação de vazão nos produtores durante o período de produção do reservatório. A fun-

ção objetivo (VPL – Valor Presente Líquido) é escrita conforme já apresentado na Equação 1.4.

Dois ciclos de controle são usados durante um período de produção de 16 anos. O primeiro é referente aos seis primeiros anos de produção e outro com relação ao período dos dez anos restantes. As variáveis de projeto são as porcentagens de alocação de vazão no poço produtor P-1 para cada ciclo de controle, a vazão no poço P-2 é o complemento para atingir 100% da vazão na plataforma. A porcentagem mínima de alocação é 25% e a máxima 75%, logo, o espaço de projeto é bidimensional com as seguintes restrições:

$$0,25 \leq x_1, x_2 \leq 0,75 \quad (3.18)$$

Os dados de produção necessários para o cálculo do VPL serão obtidos pelo simulador numérico de reservatórios Imex (CMG, 2006). O reservatório é discretizado numa malha de diferenças finitas da forma 51 x 51 x 1. Os blocos da malha possuem dimensões constantes de (10 m, 10 m, 4 m). Para construir os modelos substitutos foram usadas 20 amostras no domínio investigado. Na Figura 3.11, temos as amostras obtidas para todos os métodos de DOE discutidos neste trabalho.

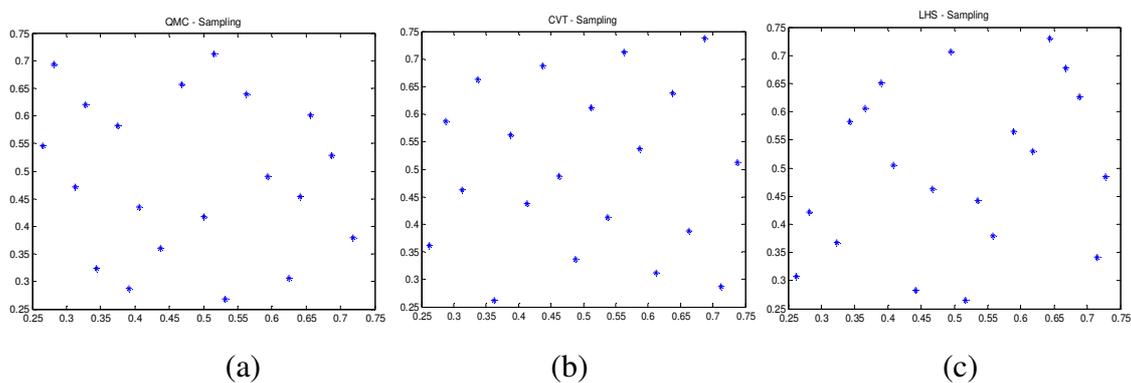


Figura 3.11: Amostras obtidas por DOE na aplicação de engenharia de reservatórios: (a) QMC, (b) LCVT and (c) LHS.

Foram definidos quatro casos com diferentes restrições, conforme tabela abaixo:

Casos	Restrições nos poços
C1	Nenhuma restrição
C2	Pressão de fundo de poço (BHP) máximo nos produtores – 180 Kgf/cm ²
C3	Corte de água (WC) máximo nos produtores – 95%
C4	Ambas as restrições de BHP e WC dos casos C2 e C3

Tabela 3.1: Condições de restrição nos poços.

As superfícies e contornos que representam as funções objetivo de alta fidelidade são mostradas nas Figuras 3.12 a 3.19, para os quatro casos mostrados na Tabela 3.1. Como pode ser observada, a função tem um comportamento que varia de plano e suave (caso C1) até características altamente não lineares e não diferenciáveis (caso C4).

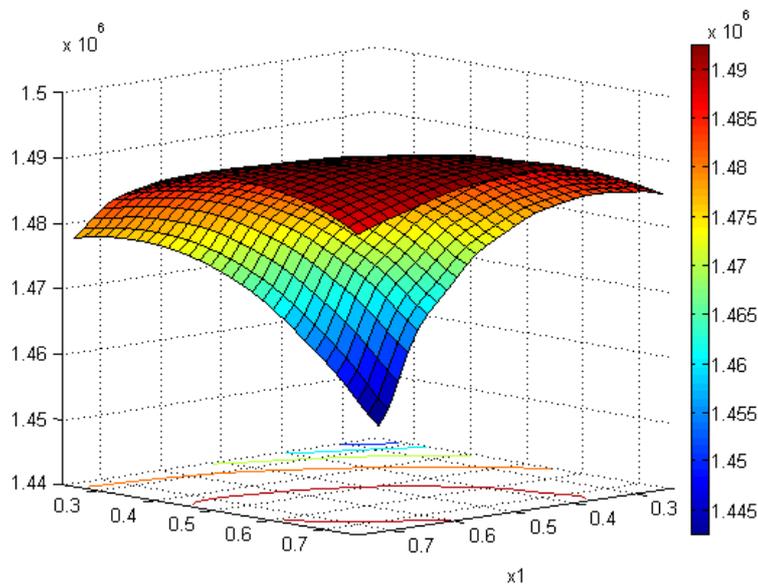


Figura 3.12: Superfícies de VPL para o caso C1 (Nenhuma Restrição).

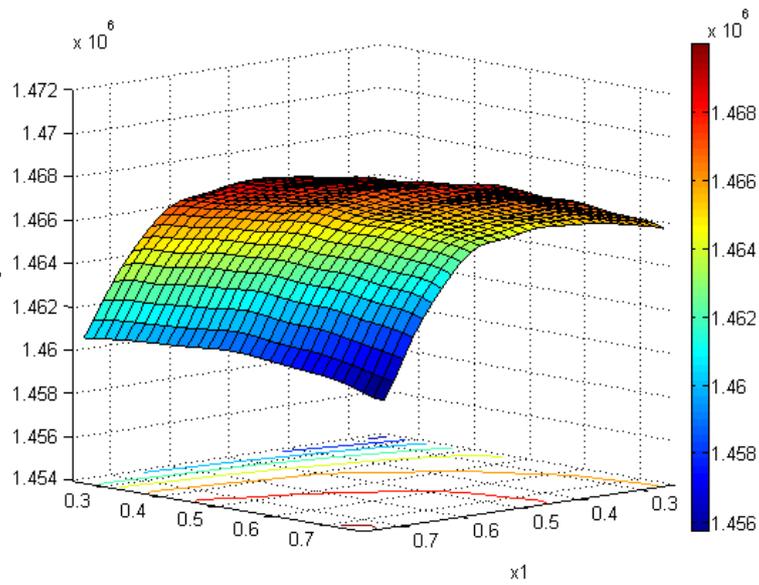


Figura 3.13: Superfícies de VPL para o caso C2 (Restrição de BHP).

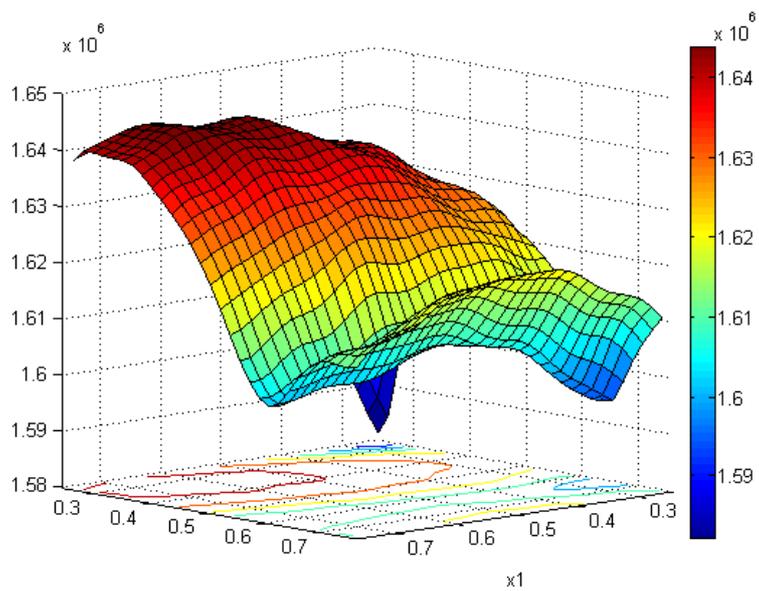


Figura 3.14: Superfícies de VPL para o caso C3 (Restrição de corte de água - WC).

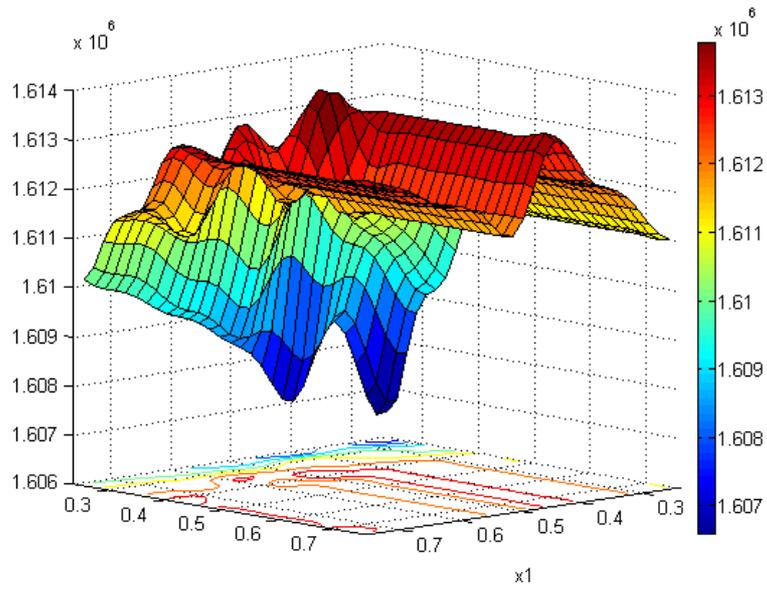


Figura 3.15: Superfícies de VPL para o caso C4 (Restrição de BHP e WC).

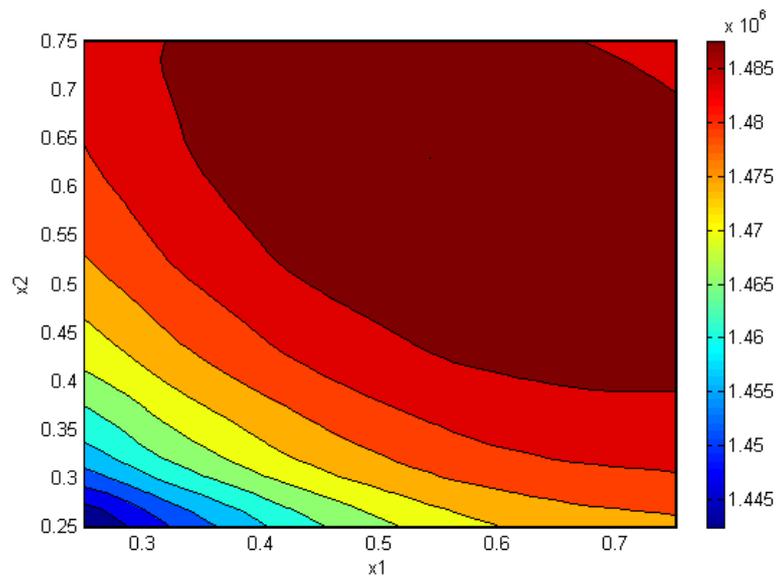


Figura 3.16: Contornos da função de VPL para o caso C1 (nenhuma restrição).

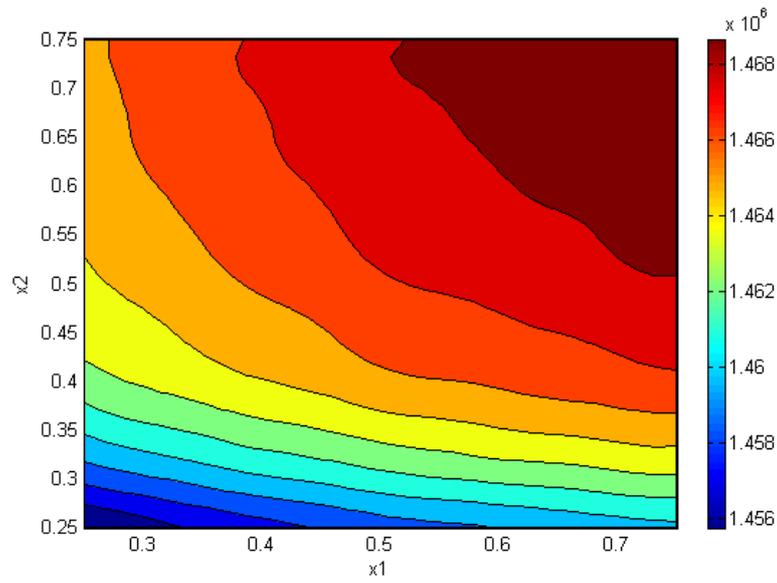


Figura 3.17: Contornos da função de VPL para o caso C2 (Restrição de BHP).

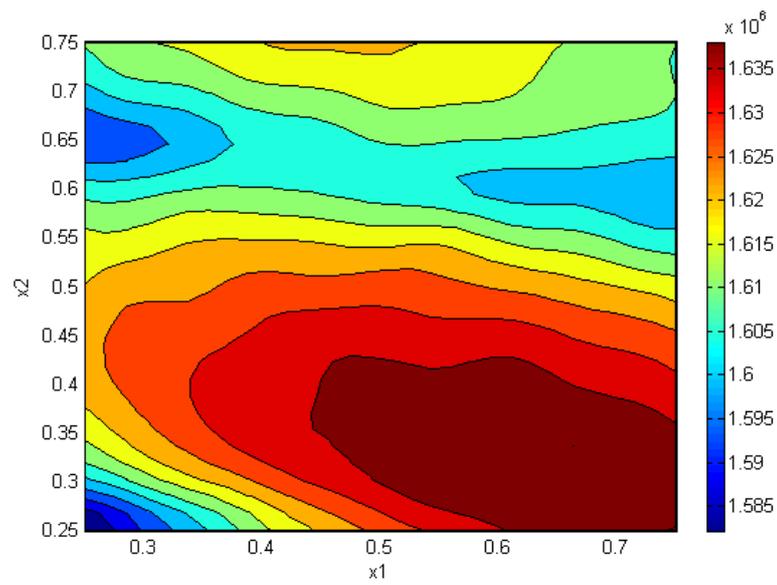


Figura 3.18: Contornos da função de VPL para o caso C3 (Restrição de corte de água - WC).

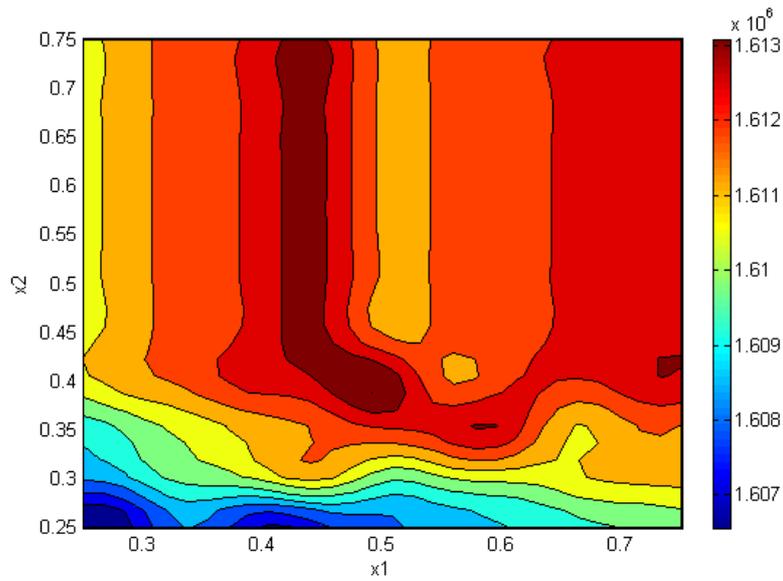


Figura 3.19: Contornos da função de VPL para o caso C4 (Restrição de BHP e WC).

Nove modelos são analisados e comparados: três diferentes técnicas de DOE (QMC, LCVT e LHS) e três diferentes tipos de modelos substitutos por amostragem (Krigagem, Processo Gaussiano e MARS).

O desempenho de cada modelo, cada tipo de restrição da Tabela 3.1, foi analisado e os resultados podem ser visualizados nas Tabelas 3.2, 3.3, 3.4 e 3.5, onde o erro RMSE é mostrado. As métricas foram avaliadas num modelo de alta fidelidade com amostras igualmente espaçadas numa malha de 11 x 11.

DOE	Krigagem	GP	MARS
QMC	485	486	4659
LCVT	334	335	5283
LHS	907	2613	2613

Tabela 3.2: Resultados do erro RMSE para a avaliação do VPL: caso C1.

DOE	Krigagem	GP	MARS
QMC	283	468	418
LCVT	165	165	279
LHS	218	218	393

Tabela 3.3: Resultados do erro RMSE para a avaliação do VPL: caso C2.

DOE	Krigagem	GP	MARS
QMC	3543	3544	11941
LCVT	5097	5097	9898
LHS	4068	4068	11035

Tabela 3.4: Resultados do erro RMSE para a avaliação do VPL: caso C3.

DOE	Krigagem	GP	MARS
QMC	1047	1297	963
LCVT	836	836	761
LHS	919	919	728

Tabela 3.5: Resultados do erro RMSE para a avaliação do VPL: caso C4.

As superfícies aproximadas e os contornos, para o melhor caso de DOE em cada caso de restrição, são mostradas nas Figuras 3.20 a 3.27. As superfícies, como mostrado nas figuras, são suaves e continuamente diferenciáveis.

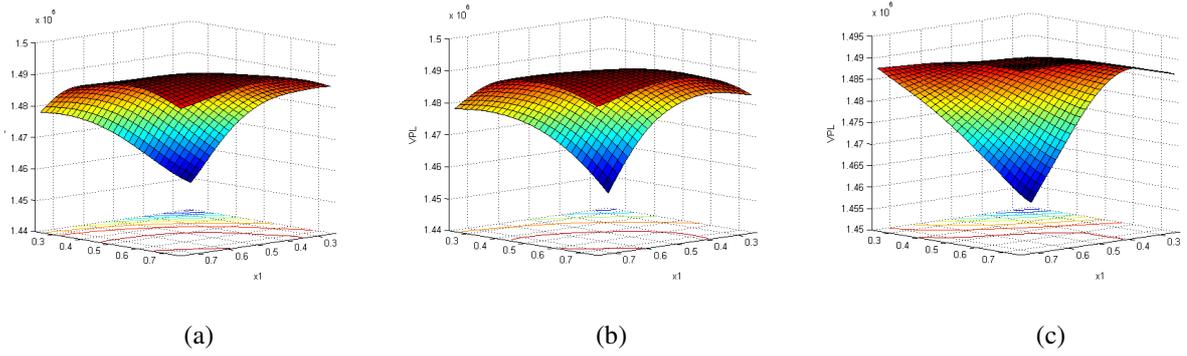


Figura 3.20: Superfícies do VPL para a condição de restrição do caso C1: (a) K , (b) GP e (c) MARS.

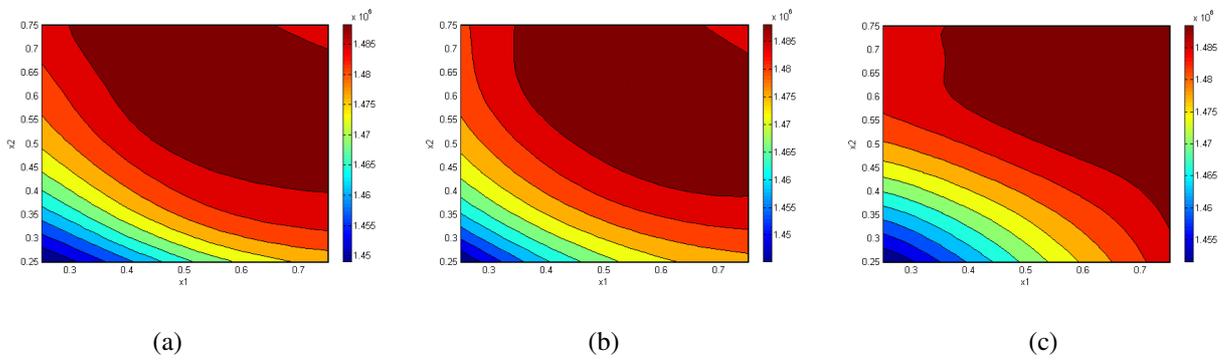


Figura 3.21: Contornos do VPL para a condição de restrição do caso C1: (a) K , (b) GP e (c) MARS.

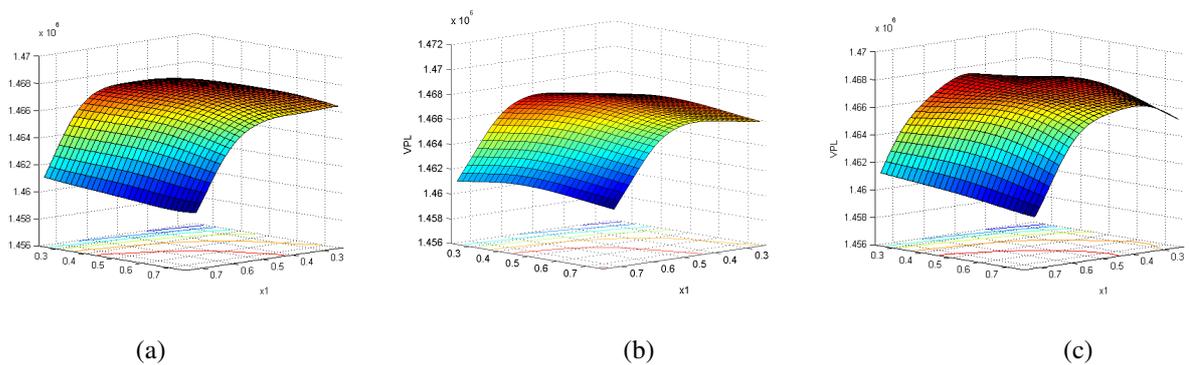


Figura 3.22: Superfícies do VPL para a condição de restrição do caso C2: (a) K , (b) GP e (c) MARS.

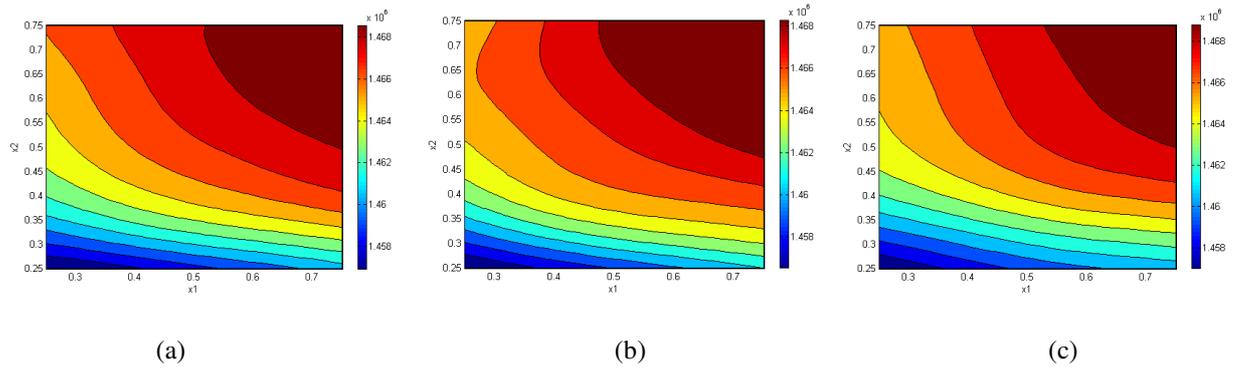


Figura 3.23: Contornos do VPL para a condição de restrição do caso C2: (a) K , (b) GP e (c) MARS.

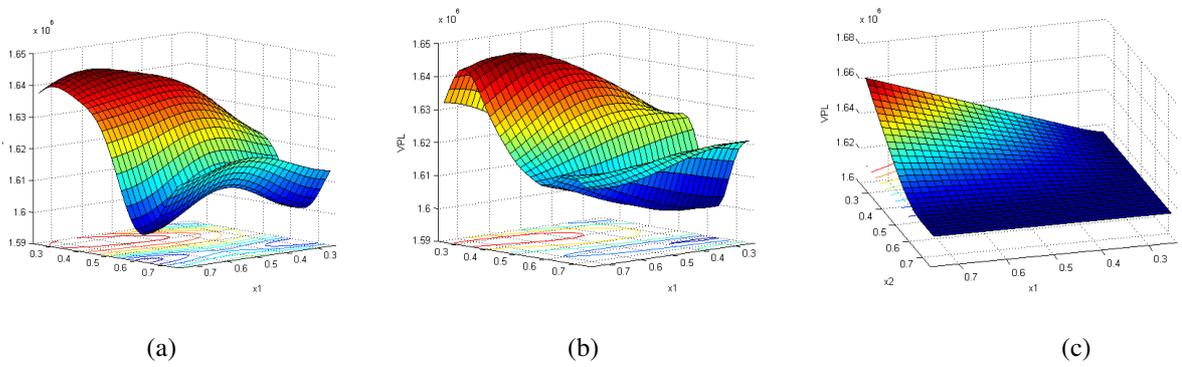


Figura 3.24: Superfícies do VPL para a condição de restrição do caso C3: (a) K , (b) GP e (c) MARS.

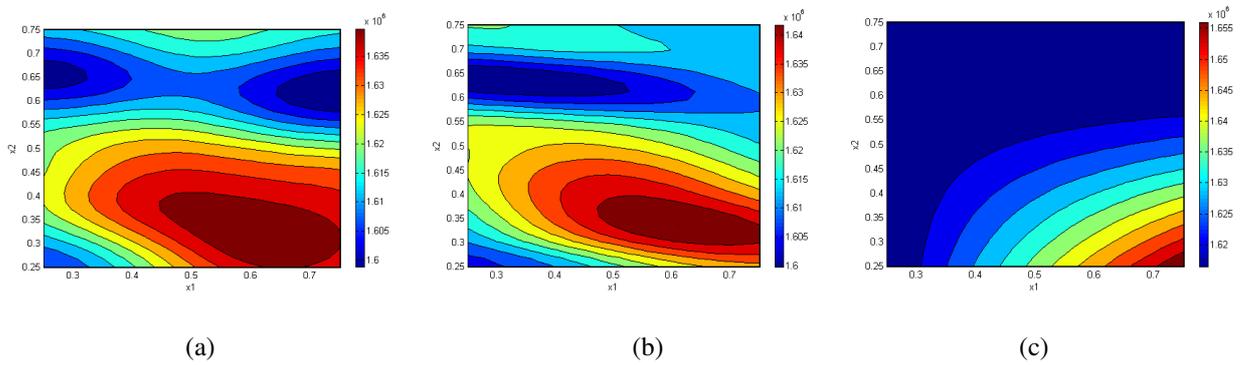


Figura 3.25: Contornos do VPL para a condição de restrição do caso C3: (a) K , (b) GP and (c) MARS.

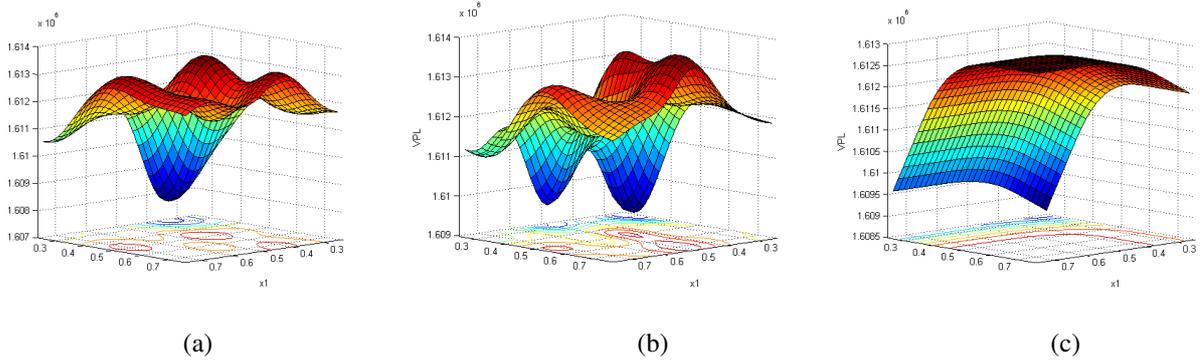


Figura 3.26: Superfícies do VPL para a condição de restrição do caso C4: (a) K , (b) GP e (c) MARS.

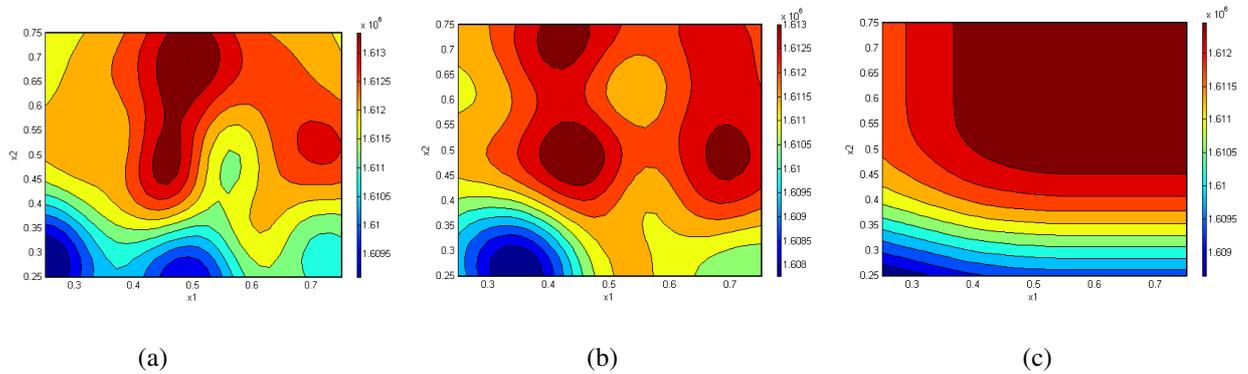


Figura 3.27: Contornos do VPL para a condição de restrição do caso C4: (a) K , (b) GP e (c) MARS.

Como pode ser visto nos resultados, considerando os DOE utilizados, LCVT é a técnica com melhor avaliação. LCVT foi melhor em 8 entre 12 casos estudados, enquanto LHS foi melhor em 2 e o QMC em também 2. Mantendo a técnica de DOE fixa, a Krigagem foi melhor em 9 dos 12 casos de construção de modelos substitutos estudados, seguido por Processo Gaussiano (GP) que atingiu o mesmo desempenho da Krigagem em 6 casos. Analisando todos os resultados obtidos, podemos verificar para o problema proposto neste trabalho que a melhor combinação foi LCVT-Krigagem, sendo esta a combinação a ser usada nos estudos de otimização, propagação de incertezas e

ajuste de histórico. É importante ressaltar que para condição de restrição C4, o método MARS mostrou melhor resultado.

Capítulo 4

Propagação de Incertezas

4.1 Introdução

A inclusão da incerteza nas simulações computacionais de reservatórios de petróleo vem se tornando essencial na busca de estimativas ótimas de produção e lucro. O conhecimento das propriedades petrofísicas referentes aos reservatórios é sempre incerto, e esta incerteza deve ser considerada no desenvolvimento de simulações computacionais. O escoamento de fluidos em reservatórios de petróleo é determinado a partir dos valores e da distribuição espacial das propriedades petrofísicas, devido à incerteza relacionada a estas propriedades, os resultados de simulações de reservatórios também devem ser considerados incertos. É evidente que a incerteza em variáveis de entrada do modelo computacional afeta diretamente as estimativas de produção e o gerenciamento dos campos de petróleo.

Propagação de incertezas significa determinar as estatísticas de uma determinada resposta referente a um modelo matemático ou computacional, a partir de distribuições de probabilidades nos parâmetros de entrada. O modelo computacional utilizado neste trabalho é composto pelas equações de escoamento multifásico em meios porosos (Abou-Kassem et al, 2006; Rosa et al, 2006), resolvidas de acordo com o modelo black-oil implementado no simulador comercial Imex (CMG, 2006). O campo de permeabilidades é considerado como um campo estocástico, caracterizando a incerteza como uma variável de entrada no modelo.

Considerando o campo de permeabilidades do reservatório como um campo estocástico, várias são as possibilidades de realizações referentes aos valores de permeabilidade deste campo, honrando suas características geológicas. Existem evidências numéricas de que o problema matemático de simulação (estocástica) de reservatórios possui uma dimensão pequena, significando que o problema estocástico depende apenas de um número relativamente pequeno de variáveis aleatórias. Neste caso, uma forma possível de descrever os campos randômicos consiste em utilizar a expansão de Karhunen-Loeve (K-L) (Tatang, 1995; Huang et al, 2001; Sarma et al, 2008). A expansão de K-L parametriza o campo de permeabilidades em termos de um pequeno conjunto de variáveis independentes, a partir do conhecimento de uma matriz de covariância. Entretanto, a expansão de K-L possui uma grande desvantagem, o alto custo computacional, problema que pode ser resolvido utilizando a técnica da matriz núcleo. A expansão de K-L desenvolvida no espaço original das realizações, com funções núcleo de polinômios de primeira ordem somente irá preservar os momentos de primeira e segunda ordem (estatística de dois pontos), ou seja, não poderá representar canais, estratificação, fácies ou outras estruturas geológicas. A expansão de K-L quando realizada no espaço original das realizações é também chamada de análise de componentes principais linear ou PCA linear. Quando utiliza a metodologia da matriz núcleo é chamada de KPCA linear (KPCA- *Kernel Principal Component Analysis*).

Funções núcleo polinomiais de alta ordem (ordem maior que 1) podem ser utilizados para gerar campos que preservem os momentos de alta ordem (maior que 2). Neste caso a expansão de K-L deve ser desenvolvida num espaço de alta ordem. Agora temos a configuração não linear da expansão de K-L. A expansão de K-L não linear, ou KPCA não linear, é desenvolvida num espaço característico F de dimensão muito maior do que a dimensão do espaço original das realizações, onde os vetores do espaço característico são relacionados com os vetores do espaço original através de uma função não linear implícita. Neste trabalho as metodologias KPCA linear e não linear foram implementadas.

No procedimento de propagação de incertezas em simulação de reservatórios, é necessário descrever algumas entradas e também as variáveis de interesse na saída como variáveis estocásticas. A expansão de K-L é usada para descrição dos campos petrofísicos de entrada, e a expansão em caos polinomial como também o método de colocação

estocástica são usados para representação das saídas. Na expansão em caos polinomial (Xiu e Karniadakis, 2003; Eldred e Webster, 2008), um processo aleatório de segunda ordem é expandido em polinômios Hermitianos de variáveis aleatórias Gaussianas. Na colocação estocástica, polinômios interpoladores em variáveis estocásticas são usados diretamente para aproximação das variáveis de saída. Processos aleatórios de segunda ordem são processos de variância finita, como acontece na maioria dos processos físicos. A utilização destas duas metodologias permite o desenvolvimento eficiente de simulações de propagação de incerteza.

Os métodos baseados em caos polinomial testados neste trabalho estão disponíveis no sistema computacional Dakota (*Design Analysis Kit for Optimization and Terascale Applications*). O Dakota (Eldred et al, 2010) é um sistema de código aberto para otimização, quantificação de incertezas, confiabilidade e estimativa de parâmetros, entre outras capacidades, para análise de problemas de grande porte de engenharia. A interface entre o Dakota e o Imex foi feita com programas de pré e pós processamento escritos em Matlab/Octave (GNU Octave, 2010).

Nos estudos iniciais deste trabalho, os campos estocásticos serão representados por expansão de K-L com polinômios da função núcleo de ordem 1, neste caso KPCA linear. Os polinômios da função núcleo serão definidos mais adiante. Inicialmente foram realizados estudos com metodologias clássicas como Monte Carlo (Halton, 1970; Oliver et al, 2008), baseadas em amostragem aleatória. Foram percebidas dificuldades no que diz respeito ao número de amostragens (simulações determinísticas), possivelmente na ordem de 10^3 e 10^4 . Com o uso de simulações completas, estudos realistas estarão impossibilitados pelo tempo máquina, mesmo com o auxílio de computações paralelas com *clusters*. Neste trabalho a expansão em caos polinomial ou colocação estocástica são estudadas e utilizadas como alternativa ao método de Monte Carlo.

Definida a representação dos campos estocásticos com a expansão de K-L, a etapa seguinte será a utilização da expansão em caos polinomial e colocação estocástica para representar as saídas. Como esperado, uma redução substancial do esforço computacional é obtida, sendo possível uma considerável diminuição do número de simulações do modelo de alta fidelidade.

4.2 Expansão de Karhunen-Loeve (K-L)

A partir da consideração que o campo de permeabilidades do reservatório é um campo estocástico, várias são as possibilidades de realizações. Com o objetivo de honrar as características geológicas e geofísicas do reservatório, as realizações são obtidas com o auxílio de técnicas geoestatísticas utilizadas a partir de medições em poços e das medições sísmicas no reservatório. Para os estudos neste trabalho, as realizações foram criadas a partir de uma função de covariância conhecida (Ghanem, 1998) e com o auxílio do pacote computacional de estatística do Matlab (Mathworks, 2001). Espera-se que as metodologias implementadas neste trabalho possam no futuro utilizar realizações reais de reservatórios. A função de covariância usada está mostrada na equação 4.1:

$$\text{cov}(x, y) = \sigma_E e^{-\frac{(|x_1 - y_1|)}{b_1} - \frac{(|x_2 - y_2|)}{b_2}} \quad (4.1)$$

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.

A expansão de K-L é uma técnica que permite representar campos aleatórios estacionários e fracamente estacionários com o conhecimento explícito de funções de covariância. Sendo assim, um campo aleatório pode ser representado como uma combinação linear, envolvendo um conjunto de variáveis determinísticas com seus respectivos coeficientes aleatórios, como apresentado por Sarma et al.(2008).

Considerando y_k um conjunto de realizações discretas centradas condicionadas ou não condicionadas de um campo estocástico, com $k = 1, \dots, N_r$ ($y_k \in R^{N_c}$), lembrando que neste trabalho as realizações y_k foram geradas a partir da equação 4.1. A matriz de covariância numérica das realizações y_k pode ser calculada com a seguinte expressão, de acordo com Scholkopf et al (1996):

$$C = \frac{1}{N_r} \sum_{j=1}^{N_r} y_j y_j^T \quad (4.2)$$

Na Equação 4.2, N_r é o número de realizações, que deve ser grande o bastante para garantir a convergência da matriz de covariância \mathbf{C} . A expansão de K-L discreta, usada para gerar realizações com a matriz de covariância \mathbf{C} é apresentada na seguinte forma (Sarma et al, 2008):

$$\mathbf{y} = \mathbf{E}\mathbf{\Lambda}^{1/2}\boldsymbol{\xi} \quad (4.3)$$

Nesta equação, \mathbf{E} é a matriz dos autovetores da matriz de covariância \mathbf{C} , $\mathbf{\Lambda}$ é a matriz diagonal de autovalores de \mathbf{C} , e $\boldsymbol{\xi}$ é um vetor de variáveis aleatórias não correlacionadas com média zero e desvio padrão unitário. A expansão de K-L é uma parametrização de \mathbf{y} na forma $\mathbf{y} = f(\boldsymbol{\xi})$ onde a relação funcional é linear. 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 $\boldsymbol{\xi}$ de tamanho $N_c \times 1$, onde N_c é o número total de blocos do reservatório. O desenvolvimento da expansão de K-L implica na solução do seguinte problema de autovetores e autovalores, Scholkopf et al. (1996):

$$\lambda \mathbf{v} = \mathbf{C}\mathbf{v} \quad (4.4)$$

Onde λ é um autovalor de \mathbf{C} , e \mathbf{v} um autovetor de \mathbf{C} . A solução de equação com algoritmos padrões como SVD (*Single Value Decomposition*) é um processo computacionalmente caro, com ordem de complexidade $O(N_c^3)$ (Golub e Loan, 1996). Em problemas reais de reservatórios de petróleo, devido ao alto custo computacional, fica impossível resolver esta equação numericamente. Uma alternativa para calcular os autovetores e autovalores da Equação 4.4 é uma formulação conhecida como técnica da matriz núcleo (KPCA) (Sarma et al, 2008; Scholkopf et al, 1996).

4.3. Expansão de Karhunen-Loeve com a Utilização da Matriz Núcleo (KPCA)

A expansão de K-L como comentado anteriormente possui uma grande desvantagem, o alto custo computacional, problema que pode ser resolvido com a utilização da matriz núcleo. A partir da Equação 4.4, e com a formulação da matriz de covariância dada pela Equação 4.2, de acordo com Scholkopf et al. (1996), a seguinte equação é obtida:

$$Cv = \frac{1}{N_r} \sum_{j=1}^{N_r} (y_j \cdot v) y_j \quad (4.5)$$

A partir de equação anterior, temos que todos os vetores soluções v com $\lambda \neq 0$ encontram-se no espaço gerado por N_r realizações (y_1, \dots, y_{N_r}) , portanto, a Equação 4.4 pode ser reescrita da seguinte forma (Sarma et al, 2008):

$$\lambda(y_k \cdot v) = (y_k \cdot Cv) \quad (4.6)$$

Com $k = 1, \dots, N_r$. Também a partir da Equação 4.5, pode-se afirmar que existe coeficientes α_j , tal que v pode ser expresso da seguinte forma (Scholkopf, 1996):

$$v = \sum_{j=1}^{N_r} \alpha_j y_j \quad (4.7)$$

Combinando as equações 4.6 e 4.7, temos:

$$\lambda \sum_{i=1}^{N_r} \alpha_i (y_k \cdot y_i) = \frac{1}{N_r} \sum_{i=1}^{N_r} \alpha_i \left(y_k \cdot \sum_{j=1}^{N_r} y_j \right) (y_j \cdot y_i) \quad (4.8)$$

Definindo a matriz \mathbf{K} de tamanho $N_r \times N_r$ como $K_{ij} = (y_i \cdot y_j)$, ou seja, K_{ij} é o produto interno das realizações i e j , logo a Equação 4.8 pode ser escrita da seguinte forma:

$$N_r \lambda \mathbf{K} \boldsymbol{\alpha} = \mathbf{K}^2 \boldsymbol{\alpha} \quad (4.9)$$

A matriz \mathbf{K} é conhecida como matriz núcleo, com tamanho $N_r \times N_r$, lembrando que a matriz de covariância \mathbf{C} é de tamanho $N_c \times N_c$. $K_{ij} = (y_i \cdot y_j)$ é chamado de função polinomial núcleo de ordem 1. A Equação 4.9 pode ser escrita da seguinte forma:

$$N_r \lambda \boldsymbol{\alpha} = \mathbf{K} \boldsymbol{\alpha} \quad (4.10)$$

A Equação 4.10 é conhecida como problema de autovalor do núcleo. Resolver esta equação é equivalente a resolver a Equação 4.4. Logo, $N_r \lambda$ são os autovalores da matriz \mathbf{K} e $\boldsymbol{\alpha}$ são os respectivos autovetores. É importante ressaltar que os autovetores \boldsymbol{v} de \mathbf{C} podem ser obtidos a partir de uma combinação linear das autovetores $\boldsymbol{\alpha}$ da matrix \mathbf{K} .

A principal vantagem de utilizar este método é que podemos resolver a Equação 4.10, em vez de resolver diretamente a Equação 4.4, lembrando que geralmente $N_r \ll N_c$. A matriz núcleo \mathbf{K} foi calculada utilizando a seguinte forma:

$$K_{ij} = (y_i \cdot y_j)^d \quad (4.11)$$

A expansão de K-L desenvolvida no espaço original das realizações R^{N_c} , com matriz núcleo de polinômios de primeira ordem ($d = 1$), somente irá preservar os momentos de primeira e segunda ordem (estatística de dois pontos), ou seja, não poderá representar canais, estratificação, fácies ou outras estruturas geológicas.

$$\Phi : R^{N_c} \rightarrow F; \quad Y = \Phi(y); \quad y \in R^{N_c}, Y \in F. \quad (4.12)$$

Agora a matriz de covariância do espaço F é dada por:

$$\bar{C} = \frac{1}{N_r} \sum_{j=1}^{N_r} \Phi(y_j) \Phi(y_j)^T \quad (4.13)$$

A dimensão da matriz de covariância \bar{C} não é $N_c \times N_c$ e sim $N_F \times N_F$, onde N_F é o tamanho de $\Phi(y)$, lembrando que $N_F > N_c$. As realizações Y devem ser centralizadas no espaço F (Scholkopf et al , 1996). Da mesma forma apresentada para a expansão de K-L linear:

$$\lambda v = \bar{C} v \quad (4.14)$$

Onde λ é um autovalor de \bar{C} e v um autovetor de \bar{C} . Em vez de resolver este problema diretamente, o problema de autovalor do núcleo é formulado.

$$N_r \lambda \alpha = K \alpha \quad (4.15)$$

A matriz núcleo K na KPCA não linear não é a mesma utilizada na KPCA linear, sendo definida como:

$$K : K_{ij} = (\Phi(y_i) \cdot \Phi(y_j)) \quad (4.16)$$

Agora cada elemento da matriz núcleo é um produto interno dos vetores no espaço F, e não o produto de vetores no espaço original R^{N_c} . A dimensão da matriz núcleo continua $N_r \times N_r$, como no caso da configuração linear da expansão K-L. No cálculo da matriz K , somente é necessário o produto interno dos vetores no espaço F, ou seja, não é

necessário fazer o cálculo explícito do mapeamento $\Phi(y)$. O cálculo do produto interno pode ser realizado eficientemente através de uma função conhecida como função núcleo $k(x,y)$, onde x e y são realizações do campo estocástico no espaço R^{N_c} .

$$(\Phi(x).\Phi(y)) = k(x, y) \quad (4.17)$$

A função núcleo $k(x,y)$ calcula o produto interno no espaço F diretamente dos elementos no espaço original R^{N_c} . A função núcleo utilizada neste trabalho é o polinômio definido como:

$$(\Phi(x).\Phi(y)) = k(x, y) = (x.y)^d \quad (4.18)$$

Onde d é a ordem da função polinomial do núcleo. Desenvolver a expansão de K-L no espaço F, com polinômio núcleo de ordem d , corresponde a preservar os momentos de $2d$ ordem. Com o objetivo de preservar não somente os momentos de ordem $2d$, mas também todos os outros momentos de menor ordem a seguinte função núcleo será usada:

$$(\Phi(x).\Phi(y)) = k(x, y) = \sum_{i=1}^d (x.y)^i \quad (4.19)$$

Após a expansão de K-L no espaço F, as realização produzidas estarão no espaço F. No entanto, precisamos das realizações no espaço original, pois o objetivo é parametrizar os campos estocásticos no espaço original R^{N_c} . Para obter a realização y qualquer no espaço original correspondente a realização Y no espaço F, um mapeamento inverso de Y é requerido, ou seja, $y = \Phi^{-1}(Y)$. A técnica usada para fazer este mapeamento inverso será a técnica do problema de pré-imagen (Scholkopf et al, 1998).

4.4.1 Problema da Pré-Imagem

Resolver o problema da pré-imagem diretamente não é possível muitas vezes devido a alta dimensão do espaço F , também é importante considerar que a pré-imagem pode não existir e se existir pode ser não única (Scholkopf et al, 1998). Uma das formas de resolver o problema é transformá-lo em uma minimização do erro entre $\Phi(y)$ e Y , de acordo com a equação abaixo (Sarma et al, 2008; Kwork e Tsang, 2003).

$$\min \rho(y) = \|\Phi(y) - Y\|^2 = \Phi(y) \cdot \Phi(y) - 2Y \cdot \Phi(y) + Y \cdot Y \quad (4.20)$$

Da mesma forma como desenvolvido para o caso da expansão de Karhunen-Loeve no espaço original das realizações, temos agora para o espaço de alta ordem.

$$Y = \sum_{i=1}^{N_r} \beta_i \Phi(y_i) \quad (4.21)$$

Os coeficientes β_i são definidos da seguinte forma:

$$\beta_i = \frac{1}{\sqrt{N_r}} \sum_{j=1}^{N_r} \alpha_{ij} \delta_j^{1/2} \xi_j \quad (4.22)$$

Onde α é a matriz de autovetores e δ são os autovalores, ambos da matriz núcleo K . Substituindo 4.21 e 4.22 na equação 4.20, e igualando o gradiente da função resultante a zero (mínimo da função), e considerando ainda a equação 4.19, a seguinte equação é obtida:

$$\sum_{j=1}^d j(y \cdot y)^{j-1} y - \sum_{i=1}^{N_r} \beta_i \sum_{j=1}^d j(y_i \cdot y)^{j-1} y_i = 0 \quad (4.23)$$

A equação 4.23 é uma parametrização implícita não-linear da forma $f(y, \xi) = 0$. Uma das formas de resolver a equação para encontrar y para um dado ξ é aplicar o método de iteração do ponto fixo, onde a seguinte equação é obtida

$$y^{k+1} = \frac{\sum_{i=1}^{N_r} \beta_i \sum_{j=1}^d j (y_i \cdot y^k)^{j-1} y_i}{\sum_{j=1}^d j (y^k \cdot y^k)^{j-1}} \quad (4.24)$$

Encontrar y utilizando a equação 4.24 apresenta problemas de estabilidade, uma das formas de minimizar este problema é realizar uma alteração no denominador da equação 4.24. (Sarma et al, 2008), logo a equação ficará da seguinte forma:

$$y^{k+1} = \frac{\sum_{i=1}^{N_r} \beta_i \sum_{j=1}^d j (y_i \cdot y^k)^{j-1} y_i}{\sum_{i=1}^{N_r} \beta_i \sum_{j=1}^d j (y_i \cdot y^k)^{j-1}} \quad (4.25)$$

Portanto, a utilização da equação 4.25 é uma alternativa para encontrar a realização y correspondente ao problema da pré-imagem. É importante observar que a utilização da equação 4.25 torna possível gerar realizações y a partir de um vetor de variáveis aleatórias não correlacionadas ξ . Uma característica importante da realização gerada com a equação 4.25 é que a realização mantém a estrutura geológica do campo de permeabilidades, entretanto os valores das permeabilidades estão modificados. Os valores das permeabilidades serão ajustados no processo de ajuste de histórico. Portanto, neste trabalho a metodologia KPCA não linear será aplicada apenas para realização de ajuste de histórico.

4.5 Expansão em Caos Polinomial

A expansão em caos polinomial permite que um processo aleatório de segunda-ordem seja expandido em termos de polinômios Hermitianos em variáveis aleatórias Gaussianas (Eldred e Webster, 2008). Um caos polinomial é uma expressão em termos de polinômios ortogonais em variáveis estocásticas, composta por um somatório infinito no grau do polinômio, de somatórios infinitos no número de variáveis aleatórias de polinômios ortogonais. Uma variável aleatória de segunda-ordem $S(\theta)$, sendo θ um evento independente, pode ser representada da seguinte forma (Xiu e Karniadakis, 2003):

$$\begin{aligned}
 S(\theta) = & a_0\phi_0 + \sum_{i_1=1}^{\infty} a_{i_1}\phi_1(\xi_{i_1}(\theta)) + \sum_{i_1=1}^{\infty} \sum_{i_2=1}^{i_1} a_{i_1 i_2}\phi_2(\xi_{i_1}(\theta), \xi_{i_2}(\theta)) \\
 & + \sum_{i_1=1}^{\infty} \sum_{i_2=1}^{i_1} \sum_{i_3=1}^{i_2} a_{i_1 i_2 i_3}\phi_3(\xi_{i_1}(\theta), \xi_{i_2}(\theta), \xi_{i_3}(\theta)) + \dots
 \end{aligned} \tag{4.26}$$

Onde $\phi_n(\xi_{i_1}, \dots, \xi_{i_n})$ são os polinômios Hermitianos de ordem n em função das variáveis aleatórias Gaussianas independentes ξ_i , $i = 1, \dots, \infty$, com média zero e variância unitária. A expressão geral para os polinômios hermitianos ϕ_n é dada por (Xiu e Karniadakis, 2003):

$$\phi_n(\xi_{i_1}, \dots, \xi_{i_n}) = \exp\left(\frac{1}{2}\xi^t \xi\right) (-1)^n \frac{\partial^n}{\partial \xi_{i_1} \dots \partial \xi_{i_n}} \exp\left(-\frac{1}{2}\xi^t \xi\right) \tag{4.27}$$

Onde ξ é o vetor com n variáveis aleatórias Gaussianas. A definição de ortogonalidade depende da definição de um produto interno, que no caso é dada pela Equação. 4.28

$$\langle \phi_i, \phi_j \rangle = \int_{\xi_1 \xi_2 \dots} \phi_i(\xi_1, \xi_2, \dots) \phi_j(\xi_1, \xi_2, \dots) \rho(\xi_1, \xi_2, \dots) d\xi_1 d\xi_2 \dots \tag{4.28}$$

Nesta equação, $\rho(\xi_1, \xi_2, \dots)$ é a densidade conjunta de probabilidade das variáveis incertas. Os polinômios ϕ_i e ϕ_j são ortogonais quando o produto interno definido pela Equação 4.28 é nulo.

É possível mostrar que os polinômios de grau k , em k variáveis, mostrados na Equação 4.26, podem ser escritos como produtos de k polinômios de grau k em uma variável, isto é:

$$\phi_k(\xi_1, \xi_2, \dots, \xi_k) = \psi_k(\xi_1)\psi_k(\xi_2)\cdots\psi_k(\xi_k) = \Psi_k(\xi) \quad (4.29)$$

Onde fica subentendido que $\psi_o(\xi_i) = 1, i = 1, \dots, k$ e que ξ representa o conjunto das variáveis aleatórias. Com esta observação, é possível reescrever a Equação 4.26 em uma forma mais convencional, como um somatório infinito de termos mostrado na Equação 4.29.

$$S(\xi) = \sum_{i=1}^{\infty} \alpha_i \Psi_i(\xi). \quad (4.30)$$

Nesta equação α_i são os coeficientes a determinar, e os polinômios $\Psi(\xi)$ são conhecidos, sendo produtos de polinômios ortogonais unidimensionais como mostrado na Equação 4.29. As Equações 4.26 e 4.30 são igualdades exatas, em termos probabilísticos, mas não são de uso prático, pois dependem de um número infinito de variáveis aleatórias e de polinômios de grau infinito. Na prática, truncamos as duas coisas: usa-se um número finito de variáveis e o grau dos polinômios é limitado também, e em geral, limitado a um grau relativamente baixo, sendo a Equação 4.30 reescrita como

$$S(\xi) \approx \sum_{i=1}^N \alpha_i \Psi_i(\xi) \quad (4.31)$$

É claro que agora o somatório é apenas uma aproximação para a função desconhecida, mas mostra-se que para funções que atendem a alguns requisitos a convergência é muito rápida. N é o número de coeficientes indeterminados α_i , é dado por:

$$N = \frac{(n+p)!}{n!p!} \quad (4.32)$$

Onde n é o número de variáveis incertas e p é o grau do polinômio empregado (admitindo-se aqui o uso da mesma ordem de aproximação para todas as variáveis incertas).

O cálculo dos coeficientes da expansão referente à Equação 4.31 pode ser feito de duas formas. A técnica mais consistente teoricamente é considerar a Equação 4.31 como uma igualdade, e projetar cada lado desta igualdade ao longo de cada direção da base, isto é:

$$\langle S, \Psi_k \rangle = \left\langle \sum_{i=1}^N \alpha_i \Psi_i, \Psi_k \right\rangle \quad (4.33)$$

Como os polinômios são ortogonais, o produto escalar do lado direito na Equação 4.33 só é diferente de zero para $i = k$. Assim, pode-se escrever

$$\alpha_i = \frac{\langle S, \Psi_i \rangle}{\langle \Psi_i^2 \rangle} = \frac{1}{\langle \Psi_i^2 \rangle} \int_{\xi_1 \dots \xi_k} S(\xi_1, \dots, \xi_k) \Psi_i(\xi_1, \dots, \xi_k) \rho(\xi_1, \dots, \xi_k) d\xi_1 \dots d\xi_k. \quad (4.34)$$

O denominador da Equação 4.34 pode ser computado analiticamente, e é tabelado para as famílias de polinômios ortogonais empregados na propagação de incertezas. O numerador, no entanto, é uma integral multidimensional que precisa ser avaliada para cada problema. A técnica padrão para a avaliação desta integral é a quadratura numérica, com pontos de integração e pesos determinados segundo fórmulas Gaussianas. A função S deve ser avaliada para cada ponto de integração, e como o integrando é relativamente “complicado”, podem ser necessários muitos pontos de integração ao longo de cada dimensão para que estes coeficientes sejam avaliados precisamente. O problema

com esta técnica é que o número de pontos necessário para computar esta integral cresce exponencialmente com o número de variáveis incertas do problema.

Uma alternativa é usar regressão linear, resolvendo um problema de mínimos quadrados linear da forma

$$\mathbf{\Psi}\boldsymbol{\alpha} = \mathbf{S} \quad (4.35)$$

Onde $\boldsymbol{\alpha}$ é um vetor com os coeficientes a determinar, o vetor \mathbf{S} contém valores da função desconhecida calculados para um conjunto de pontos pré-determinados (pontos de colocação), empregando um esquema de projeto de experimentos em computador, por exemplo, e sendo a matriz $\mathbf{\Psi}$ contendo os polinômios avaliados nestes pontos. O número total de avaliações de função necessárias com esta técnica é dado por

$$N = 2 \frac{(n+p)!}{n!p!} \quad (4.36)$$

O que pode ser bem mais econômico do que a quadratura multidimensional. Neste trabalho as duas formas de obtenção dos coeficientes da expansão polinomial são empregadas.

4.6 Colocação Estocástica

O método de colocação estocástica (Eldred e Burkardt, 2009) consiste em adotar um polinômio interpolador Lagrangeano multidimensional, que passa uma série de pontos de colocação pré-definidos em uma malha regular, como mostrado na Equação 4.37.

$$S(\boldsymbol{\xi}) \approx \sum_{i=1}^{N_p} r_i L_i(\boldsymbol{\xi}) \quad (4.37)$$

Como os polinômios de Lagrange têm o valor 1 em um ponto de colocação e 0 nos demais, os coeficientes r_i da Equação 4.37 são diretamente os valores da função S nos pontos de colocação. É importante observar que o número de pontos de colocação crescem exponencialmente com o número de variáveis incertas. A utilização de malhas regulares para obtenção dos pontos de colocação pode exigir um elevado número de pontos de colocação. Uma forma de diminuir este problema é a utilização de malhas esparsas (Eldred e Burkardt, 2009), entretanto este tipo de malha não foi utilizada neste trabalho.

4.7 Estudo de Caso – Injeção de Gás em Reservatório com 2 poços

As técnicas para estudos de propagação de incertezas apresentadas foram aplicadas a um caso de reservatório de petróleo com injeção de gás (Aziz, 1981). O exemplo é também conhecido como problema SPE 1 no tutorial do simulador de reservatórios Imex (CMG, 2006).

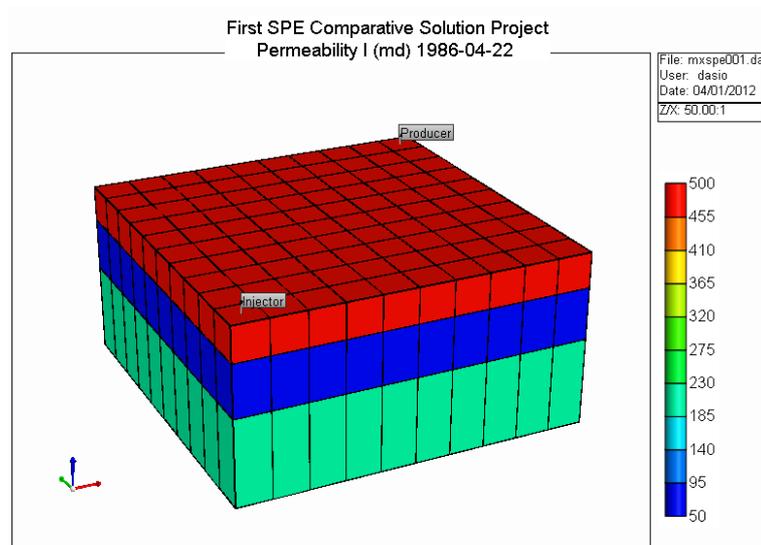


Figura 4.2: Modelo do reservatório com injeção de gás.

Neste trabalho, os estudos de propagação de incertezas foram desenvolvidos com o auxílio do sistema computacional Dakota (Eldred, 2010), e as simulações de

reservatórios foram executadas no Imex (CMG, 2006). Os programas de pré e pós processamento para intercâmbio de dados entre o Dakota e o Imex foram escritos e implementados em Octave (GNU Octave, 2010), uma linguagem tipo Matlab para o sistema operacional Linux.

No problema proposto existem dois poços, um injetor e outro produtor. O reservatório possui três camadas de permeabilidades, as camadas possuem permeabilidades horizontais constantes na direção i com os valores de 200 mD, 50mD e 500mD. As permeabilidades horizontais na direção j possuem o mesmo valor que na direção i . Os valores das permeabilidades verticais são de 20 mD, 40mD e 60 mD. O poço injetor tem a vazão constante de gás 1×10^8 ft³/dia std, já o poço produtor opera com os limites de vazão máxima de óleo de 20000 bbl/dia std. O reservatório possui dimensões de 10000 x 10000 ft² com espessura de 100 ft, sendo modelado com uma malha 10 x 10 x 3.

4.7.1 Problema com 1 Variável Incerta

Como primeiro exemplo, a permeabilidade horizontal da primeira camada foi considerada uma variável incerta, chamada de permeabilidade base, sendo as permeabilidades nesta mesma direção nas camadas dois e três com os valores de 0,25 e 2,5 vezes a permeabilidade base. As permeabilidades horizontais na direção j foram consideradas iguais as permeabilidades na direção i . As permeabilidades verticais foram consideradas 0,2 vezes os valores da permeabilidade horizontal, de forma que o problema tem apenas uma única variável incerta. O objetivo da análise foi a obtenção das estatísticas referentes ao valor presente líquido do campo (VPL), calculado de acordo com a Equação 1.4 (Oliveira, 2006).

Inicialmente, 200 mD foi o valor médio escolhido para permeabilidade base, com uma distribuição normal e desvio padrão igual a 100 mD. Infelizmente, este valor não se mostrou apropriado para demonstração de técnicas de propagação de incertezas, pois para esta faixa de valores, o VPL tem pouca variação. Como esta etapa do trabalho tem o objetivo de apenas apresentar as técnicas de propagação de incertezas, para permeabilidade base foi escolhido o valor de 70 mD, com densidade de probabilidade lognormal e desvio padrão igual a 15 mD.

Problemas de reservatório de petróleo como este não possuem solução analítica. Um estudo de propagação de incerteza com o método de Monte Carlo foi desenvolvido no modelo de alta fidelidade com o objetivo de ter uma solução aproximada, para comparação com as técnicas de caos polinomial e colocação estocástica, utilizadas neste trabalho. Os resultados obtidos com o método de Monte Carlo são mostrados na Tabela 4.1, onde estão os valores para o valor esperado, desvio padrão e coeficiente de variação do VPL, todos em função do número de amostras.

Amostras	E(VPL) (10 ⁸ US\$)	S (VPL) (10 ⁸ US\$)	COV
100	8,3508	0,4051	0,0485
200	8,2345	0,6541	0,0794
400	8,2522	0,5963	0,0723
800	8,2461	0,6088	0,0738
1600	8,2342	0,6392	0,0776
3200	8,2146	0,6922	0,0843
6400	8,2263	0,6665	0,0810
8000	8,2281	0,6739	0,0819
10000	8,2286	0,6672	0,0811

Tabela 4.1: Resultado para o método de Monte Carlo.

A Figura 4.3 mostra histogramas produzidos a partir do método de Monte Carlo, visualizando as ocorrências de permeabilidade e VPL, com também seus valores médios.

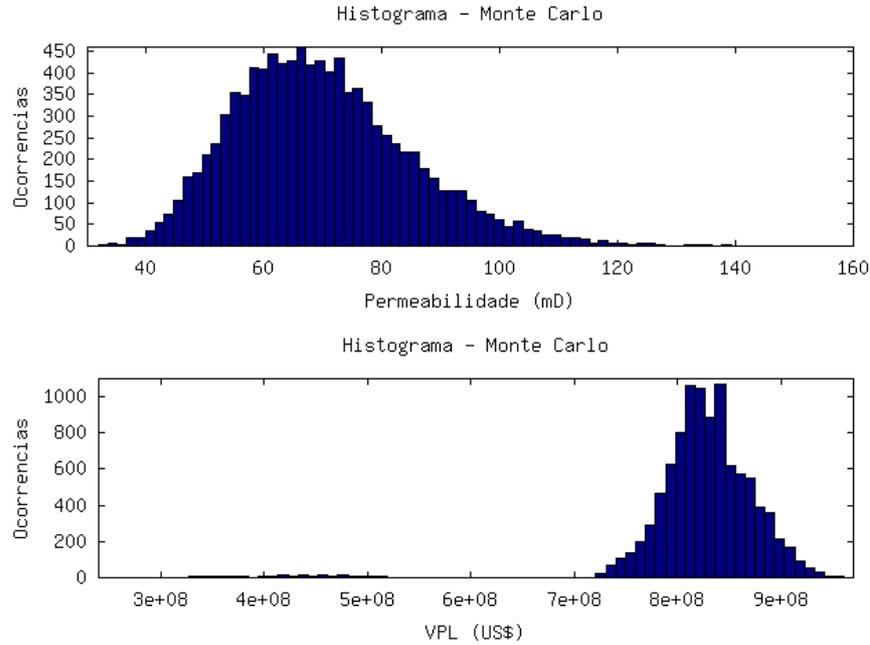


Figura 4.3: Histograma das variáveis de entrada (Permeabilidade) e de saída (VPL).

Expansão em Caos Polinomial

Há duas escolhas importantes na expansão em caos polinomial quando os coeficientes são calculados por quadratura numérica: a ordem de expansão, isto é, o grau máximo do polinômio usado na expansão, e a ordem de quadratura, isto é, o número de pontos usado na integração numérica. A quadratura Gaussiana integra exatamente um polinômio de grau $2m - 1$ com m pontos de integração, e como na integral dos coeficientes aparece um polinômio de grau pelo menos $2p$ (um polinômio de grau p , multiplicado pela função S aproximada a mais ou menos esta ordem), é de se esperar que seja necessária a ordem de quadratura $p + 1$ para o cálculo dos coeficientes com precisão adequada. Nesta seção foram feitas experiências numéricas variando-se a ordem de expansão e a ordem de quadratura, inclusive com a utilização de ordens de quadratura nitidamente abaixo do necessário, apenas para levantar o comportamento do método nesta situação extrema.

Na Tabela 4.2 são mostrados o valor esperado E , o desvio padrão S e o coeficiente de variação (COV) do VPL, computados com uma expansão de caos polinomial variando a ordem da expansão (OE), e com a respectiva ordem de quadratura

OQ ($p + 1$). Foi interessante perceber que no caso de aproximações com baixos valores para OE e OQ, os resultados foram bons, quando comparados àqueles obtidos pelo método de Monte Carlo. É importante lembrar que este caso de estudo é unidimensional, logo, o número de pontos de avaliação da função é igual à ordem de quadratura.

Estudos com variação da ordem de expansão em caos polinomial foram desenvolvidos, foi percebido que, para este problema, a ordem de quadratura pode ser estimada acima de $p + 1$, fornecendo bons resultados, mas não necessariamente os melhores. É interessante observar também que o uso de pontos de integração insuficientes fornece resultados ainda razoáveis para o valor esperado, mas pode fornecer resultados inconsistentes para a variância.

OE	OQ	E(VPL) (10^8 US\$)	S (VPL) (10^8 US\$)	COV
1	2	8,2958	0,3925	0,0473
2	3	8,2669	0,4193	0,0507
3	4	8,1591	0,8940	0,1096
4	5	8,2397	0,6530	0,0792

Tabela 4.2: Caos polinomial com 1 variável incerta.

Como pode ser visto nos resultados apresentados, valores do VPL esperado próximos do valor obtido com o método de Monte Carlo podem ser obtidos com expansões de baixa ordem. É importante ressaltar que não se deve esperar mais de dois algarismos de precisão nos resultados.

Colocação Estocástica

Os resultados obtidos utilizando o método da colocação estocástica podem ser visualizados na Tabela 4.3, onde diversas ordens de interpolação foram utilizadas. Neste caso o número de avaliações da função é um mais a ordem de interpolação.

OE	E(VPL) (10⁸ US\$)	S (VPL) (10⁸ US\$)	COV
1	8,2682	0,0000	0,0000
2	8,2958	0,3924	0,0473
3	8,2669	0,4192	0,0507
4	8,1591	0,8940	0,1096
5	8,2397	0,6530	0,0792
6	8,2749	0,4984	0,0602

Tabela 4.3: Colocação estocástica.

Os resultados do valor esperado do VPL obtidos com método da colocação estocástica, como no caso do caos polinomial, convergem com baixa ordem de interpolação, entretanto o mesmo não acontece com o desvio padrão.

4.7.2 Problema com 3 Variáveis Incertas

Neste caso foi utilizado o mesmo problema de reservatório, considerando agora três variáveis incertas no campo de permeabilidades. Neste caso as permeabilidades horizontais em cada uma das três camadas são consideradas variáveis incertas, com distribuição lognormal com os valores médios de 70 mD, 18 mD e 175 mD. Os desvios padrões são de 15 mD, 4mD, 37 mD. Os valores foram escolhidos mantendo a proporção das permeabilidades referente ao caso com uma variável incerta. As permeabilidades horizontais na direção de j são iguais as na direção i, e as permeabilidades verticais são iguais as permeabilidades na direção horizontal multiplicado por 0,2.

Na Tabela 4.4 estão os resultados obtidos para o estudo de propagação de incertezas utilizando o método de Monte Carlo.

Amostras	E(VPL) (10⁸ US\$)	S (VPL) (10⁸ US\$)	COV
100	8,5005	1,1099	0,1305
200	8,4946	1,0090	0,1187
400	8,4283	1,0220	0,1212
800	8,3985	1,0132	0,1206
1600	8,3643	0,9922	0,1186
3200	8,3571	1,0005	0,1197
6400	8,3480	1,0083	0,1207
8000	8,3476	1,0059	0,1205
10000	8,3465	1,0092	0,1209

Tabela 4.4: Resultado para o método de Monte Carlo, com 3 variáveis incertas.

Na Tabela 4.5 se observa os resultados de propagação de incertezas utilizando a expansão em caos polinomial.

OE	OQ	E(VPL) (10⁸ US\$)	S (VPL) (10⁸ US\$)	COV
2	3	8,3418	1,0008	0,1199
3	4	8,3333	1,0026	0,1203

Tabela 4.5: Expansão em caos polinomial, com 3 variáveis incertas.

Comparando os resultados da expansão polinomial (Tabela 4.5) com os resultados utilizando o método de Monte Carlo (Tabela 4.4), é verificado que o resultado obtido com utilização da ordem de expansão 2 e ordem de quadratura 3 converge para o resultado do método de Monte Carlo com 10000 amostras. Para a expansão polinomial foram necessárias $3^3 = 27$ simulações, enquanto o método de Monte Carlo converge com aproximadamente 6400 simulações.

4.7.3 Problema de Alta Dimensão

As técnicas de propagação de incerteza demonstradas acima são de grande potencial. Entretanto, no caso de um campo de permeabilidades heterogêneo seria necessário associar uma variável incerta a cada célula do reservatório. Isto tornaria inviável a utilização da metodologia em problemas reais de reservatório. Neste problema foi usada a expansão de Karhunen-Loeve, com objetivo de obter uma redução dimensional do problema real de reservatório.

Neste caso, o modelo do reservatório continua sendo o SPE 1, com a modificação relacionada ao campo de permeabilidades que agora é heterogêneo, como mostra a Figura 4.5. O campo de permeabilidades possui 1000 diferentes realizações, que neste trabalho foram geradas com a Equação 4.1 e o auxílio do pacote computacional de estatística do Matlab (Mathworks, 2001). A distribuição de probabilidades mais natural para campos de permeabilidades é a lognormal, porém os campos recuperados com a Equação 4.3 são Gaussianos. Portanto, as realizações são geradas centralizadas com distribuição normal e o desvio padrão é obtido a partir da média e desvio padrão previamente definidos na escala lognormal, ou seja, a expansão de K-L é aplicada no logaritmo natural dos campos de permeabilidade. É importante ressaltar que as realizações geradas com a equação 4.1 são centralizadas (Scholkopf et al, 1996).

Neste exemplo, desejava-se campos lognormais com média 1000 mD e desvio padrão igual a 2000 mD, e os parâmetros para a distribuição normal associada são de média igual a 6,103 e desvio padrão igual a 1,27. As realizações são geradas por camadas, sendo repetidas em cada uma das três camadas do reservatório. A Figura 4.4 mostra um gráfico da magnitude dos autovalores da matriz de covariância dos campos gerados com a equação 4.1, ordenados em ordem decrescente.

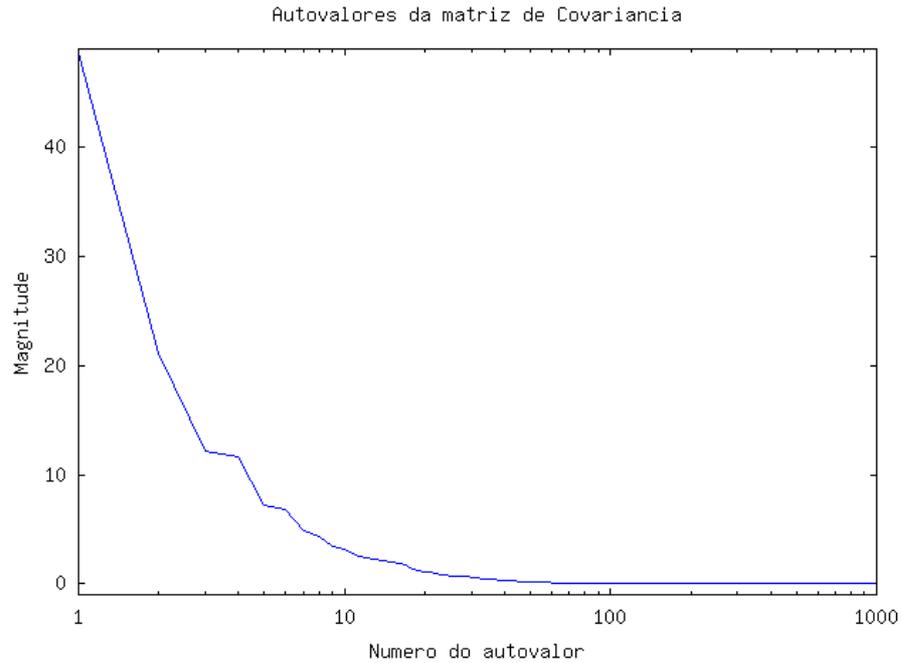


Figura 4.4: Magnitude dos autovalores da Matriz de Covariância.

Da Figura 4.4 se observa que, para os parâmetros empregados, os autovalores decaem realmente muito rapidamente. Normalmente, uma quantidade de autovalores cuja soma acumulada normalizada seja da ordem de 0,70 é uma escolha razoável. Neste caso, foram utilizados 10 autovalores e seus respectivos autovetores. Com a utilização da expansão de Karhunen-Loeve, os campos de permeabilidades podem agora ser representados por poucas variáveis aleatórias (10 variáveis neste caso). A Figura 4.5 mostra uma realização obtida com a expansão de K-L.

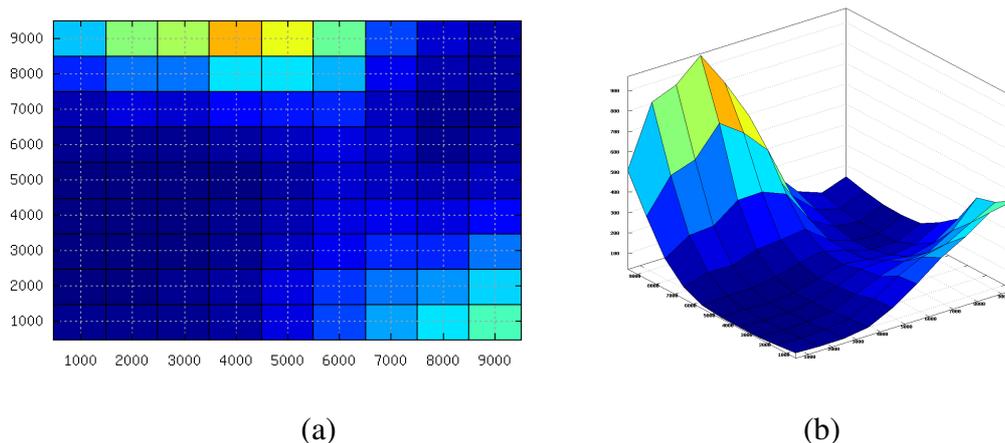


Figura 4.5: Visualização da Realização de permeabilidade obtida a partir da expansão de $K-L$: (a) vista 2d, (b) vista 3d.

Inicialmente foi desenvolvido um estudo de propagação de incertezas utilizando o método de Monte Carlo, como nos casos de uma e três variáveis incertas, as variáveis incertas são os coeficientes aleatórios da expansão de $K-L$ (ξ), caracterizando o campo de permeabilidades. Como nos casos anteriores, os objetivos são o VPL esperado e o desvio padrão. O problema de reservatório empregado possui um baixo custo computacional, é possível desenvolver estudos com o método de Monte Carlo com objetivo de servir como referência para posterior comparação com os resultados da expansão polinomial. A Tabela 4.6 mostra os resultados obtidos com o método de Monte Carlo.

Amostras	E(VPL) (10^9 US\$)	S (VPL) (10^7 US\$)	COV
1000	1,1616	8,9311	0,0768
2000	1,1593	9,8971	0,0853
4000	1,1594	10,3535	0,0892
8000	1,1585	10,8368	0,0935

Tabela 4.6: Resultado para o método de Monte Carlo, alta dimensão.

Para aplicação da expansão em caos polinomial, as variáveis ξ são usadas diretamente como as variáveis incertas na expansão ou interpolação. No caso da expansão polinomial, quando os coeficientes são calculados por quadratura numérica, os valores de ξ não são mais gerados aleatoriamente, mas vindo dos pontos de quadratura numérica. Quando os coeficientes são calculados por regressão linear, metodologia usada nesta etapa, os valores de ξ são gerados aleatoriamente, considerando sua distribuição normal com média zero e desvio padrão 1. Definido um vetor ξ (ponto de colocação), o somatório da Equação 4.3 é feito, e a realização gerada é usada em uma simulação. Após a obtenção dos resultados referentes às simulações nos pontos de colocação, a expansão em caos polinomial é desenvolvida, agora as estatísticas da função objetivo, neste caso do VPL, podem ser obtidas com o método de Monte Carlo aplicado agora na expansão polinomial.

A utilização do método de quadratura numérica para cálculo dos coeficientes da expansão possui um elevado custo computacional. Para se ter uma idéia, com apenas 10 variáveis incertas, para uma expansão polinomial de ordem 3, por exemplo, provavelmente será necessária ordem de quadratura igual a 4, o que implica em $4^{10} = 1.048.576$ avaliações de função. No caso de uma ordem de quadratura igual a 3, seriam necessárias $3^{10} = 59.049$ avaliações de função. Claramente estes números são impraticáveis. Utilizando regressão linear, o número de coeficientes a determinar para ordem de expansão 2 com 10 variáveis é igual a 66, de forma que o cálculo aproximado dos coeficientes por regressão linear requer apenas 132 avaliações, o que é viável quando se considera computação paralela. Esta foi a técnica usada neste exemplo.

A Tabela 4.7 mostra os resultados obtidos com a expansão em caos polinomial. O valor esperado do VPL obtido com a expansão de ordem dois foi satisfatório, de acordo com o resultado obtido com o método Monte Carlo. O desvio padrão obtido com a expansão de ordem dois não foi satisfatório, sendo necessário utilizar a expansão de ordem 3 para uma melhor aproximação.

OE	NP	E(VPL) (10⁹ US\$)	S (VPL) (10⁷ US\$)	COV
2	132	1,1449	14,5466	0,1270
3	572	1,1606	10,5014	0,0948

Tabela 4.7: Expansão em caos polinomial, alta dimensão.

Capítulo 5

Otimização com Simulação

5.1 Introdução

Nesta etapa do trabalho, o objetivo inicial é o desenvolvimento de metodologias e técnicas relacionadas ao processo de otimização com simulação determinística, e posteriormente, otimização com simulação estocástica. Neste contexto, serão utilizadas técnicas de fidelidade variável (Queipo et al, 2005; Simpson et al, 2004; Afonso et al, 2008; Forrester et al, 2008), em que o algoritmo de otimização opera em um modelo substituto local ao invés do modelo complexo de simulação de reservatórios (simulador *black-oil*). O modelo substituto será gerado dinamicamente a partir dos resultados de simulações.

Neste trabalho, os modelos substitutos a serem utilizados serão do tipo ajustamento de superfície. No ajustamento de superfície, técnicas de amostragem são utilizadas para gerar um conjunto de pontos no interior do espaço de projeto em estudo. Esta região é conhecida como região de confiança. (Giunta e Eldered 2000; Giunta, 2002; Simpson et al, 2004; Afonso et al, 2008). A técnica de amostragem utilizada será a LCVT (*Latin Centroidal Voronoi Tessellation*) (Giunta et al, 2003). Uma vez avaliadas as respostas das funções envolvidas na amostra, o que pode ser realizado em paralelo, o ajustamento de superfície multidimensional será realizado utilizando as técnicas de Krigagem (Jones et al, 1998; Giunta e Watson, 1998; Van Beers e Kleijnen, 2004; Forrester et al, 2008), que produz previsões mais acuradas que os modelos clássicos de regressão. Isto acontece porque enquanto na regressão clássica os erros de estimação são conside-

rados não correlacionados, na Krigagem eles são correlacionados, ou seja, quanto mais próximos forem os pontos, maiores serão as correlações.

No processo de otimização será usada a metodologia de aproximação seqüencial (SAO – *sequential approximate optimization*), onde o otimizador é executado usando o modelo substituto local limitado à região de confiança. Esta por sua vez é iterativamente ajustada até a convergência do processo. O procedimento usual de validação é aplicado comparando a melhoria prevista das respostas com aquelas obtidas da função objetivo real. Baseado no resultado da validação, o ponto encontrado é aceito ou rejeitado e o tamanho da região de confiança é expandido, contraído ou mantido (Giunta e Eldred 2000; Eldred e Dunlavy, 2006).

Na otimização em modelos substitutos, o algoritmo utilizado será o de programação quadrática sucessiva (Nocedal e Wright, 1999). No problema específico de otimização relacionado ao gerenciamento de produção de reservatórios, as ferramentas de aproximação e otimização serão acopladas ao simulador comercial Imex (CMG, 2006).

5.2 Otimização por Aproximação Seqüencial (SAO)

A estratégia de otimização por aproximação seqüencial (SAO) decompõe o processo de otimização em subproblemas, onde cada subproblema é restrito a uma região do espaço de projeto (região de confiança) (Giunta e Eldred, 2000). Em cada sub-região temos a construção de um modelo substituto local (Krigagem) no lugar do modelo real de alta fidelidade. Os modelos substitutos, como já citados, são construídos por métodos de amostragem. A formulação matemática para cada subproblema k da metodologia SAO é descrita da seguinte forma:

$$\begin{aligned}
 & \text{Maximize } \hat{f}^k(\mathbf{x}) \\
 & \text{Sujeito a: } \hat{g}_i^k(\mathbf{x}) \leq 0, \quad i = 1, \dots, m \\
 & \quad \mathbf{x}_l \leq \mathbf{x}_l^k \leq \mathbf{x} \leq \mathbf{x}_u^k \leq \mathbf{x}_u, \quad k = 0, 1, 2, \dots, k_{\max} \quad (5.1) \\
 & \text{Onde: } \quad \mathbf{x}_l^k = \mathbf{x}_c^k - \Delta^k \\
 & \quad \mathbf{x}_u^k = \mathbf{x}_c^k + \Delta^k
 \end{aligned}$$

Onde $\hat{f}^k(\mathbf{x})$ e $\hat{g}^k(\mathbf{x})$ são respectivamente as funções objetivo e restrições do modelo aproximado, \mathbf{x}_c^k é o ponto no centro da região de confiança, Δ^k é o tamanho da região de confiança, \mathbf{x}_l^k e \mathbf{x}_u^k são os limites superiores e inferiores das variáveis de projeto na iteração k da metodologia SAO.

O processo SAO é executado conforme o algoritmo abaixo:

1. Compute um determinado número de amostras do modelo de alta fidelidade, numa determinada região de confiança.
2. Construa o modelo substituto local a partir das amostras obtidas no passo 1.
3. Realize o processo de otimização no modelo substituto do passo 2.
4. Calcule a resposta no modelo de alta fidelidade da variável de controle ótima encontrada no passo 3.
5. Verifique a convergência.
6. Mova, encolha ou aumente a região de confiança, de acordo com um processo de verificação entre valores do modelo real e do modelo substituto.
7. Retorne ao passo 1.

A atualização do tamanho da região de confiança Δ^k é controlada pelo parâmetro ρ^k , este parâmetro mede a precisão da função aproximada no ponto ótimo aproximado \mathbf{x}_*^k . O cálculo de ρ^k é realizado da seguinte forma:

$$\rho^k = \min(\rho_f^k, \rho_g^k), \quad \text{for } k = 0, 1, 2, k_{\max} \quad (5.2)$$

Onde:

$$\rho_f^k = \frac{f(\mathbf{x}_c^k) - f(\mathbf{x}_*^k)}{\hat{f}(\mathbf{x}_c^k) - \hat{f}(\mathbf{x}_*^k)} \quad (5.3)$$

e

$$\rho_g^k = \frac{g(\mathbf{x}_c^k) - g(\mathbf{x}_*^k)}{\hat{g}(\mathbf{x}_c^k) - \hat{g}(\mathbf{x}_*^k)} \quad (5.4)$$

O próximo tamanho da região de confiança é atualizado como abaixo:

$$\Delta^{k+1} = \begin{cases} 0.5\Delta^k, & \text{if } \rho^k \leq 0, \\ 0.5\Delta^k, & \text{if } 0 < \rho^k \leq 0.25, \\ \Delta^k, & \text{if } 0.25 < \rho^k < 0.75 \text{ or } \rho^k > 1.25, \\ 2\Delta^k, & \text{if } 0.75 \leq \rho^k \leq 1.25 \end{cases} \quad (5.5)$$

A próxima iteração \mathbf{x}_c^{k+1} é obtida de acordo com:

$$\mathbf{x}_c^{k+1} = \begin{cases} \mathbf{x}_*^k, & \text{if } \rho^k > 0 \\ \mathbf{x}_c^k, & \text{if } \rho^k \leq 0 \end{cases} \quad (5.6)$$

Onde f e g são as funções objetivo e de restrições reais. A Figura 5.1 mostra um esquema de funcionamento da metodologia SAO.

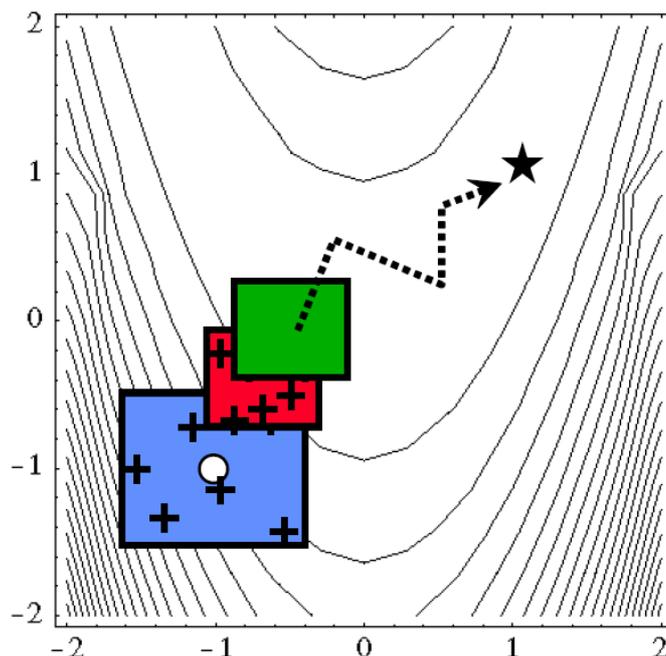


Figura 5.1: Esquema da metodologia SAO (Eldred e Dunlavy, 2006).

5.3 Otimização com Simulação Estocástica

Muitos dos problemas de otimização devem ser resolvidos considerando as incertezas devido à falta de conhecimento de propriedades referentes ao problema físico real. O desafio é incluir estas incertezas nos procedimentos de otimização com eficiência e confiabilidade.

No desenvolvimento de procedimentos de otimização considerando incertezas (OUU - *Optimization under uncertainty*), técnicas de otimização devem ser combinadas com técnicas para quantificação de incertezas (Eldred et al, 2002). Neste trabalho serão combinadas as técnicas de otimização com modelos substitutos, juntamente com estudos de propagação de incertezas, ambos apresentados nos capítulos 3 e 4.

A formulação para o desenvolvimento dos estudos de OUU apresentada neste trabalho é conhecida como camadas e aninhamento (*Layered/Nested*) (Eldred et al, 2002). Esta formulação de otimização, é baseada no uso de modelos substitutos por amostragem (*data fitting*) na qual a quantidade estatística a ser calculada é alcançada a

partir da etapa de propagação de incerteza (UQ – *Uncertainty quantification*), ou seja, a etapa de UQ é executada para cada combinação de variáveis de controle fornecidas pelo otimizador.

Na Figura 5.2 é apresentado um esquema da metodologia camadas e aninhamento, de acordo com o esquema: \hat{S}_u são as respostas da função objetivo no modelo substituto, u é a variável de estado estocástica (por exemplo, o campo de permeabilidades), e r_u é a resposta do modelo de alta fidelidade (simulador), S_u é objetivo, por exemplo, o VPL esperado, d são as variáveis de controle, que neste trabalho, são as vazões nos poços.

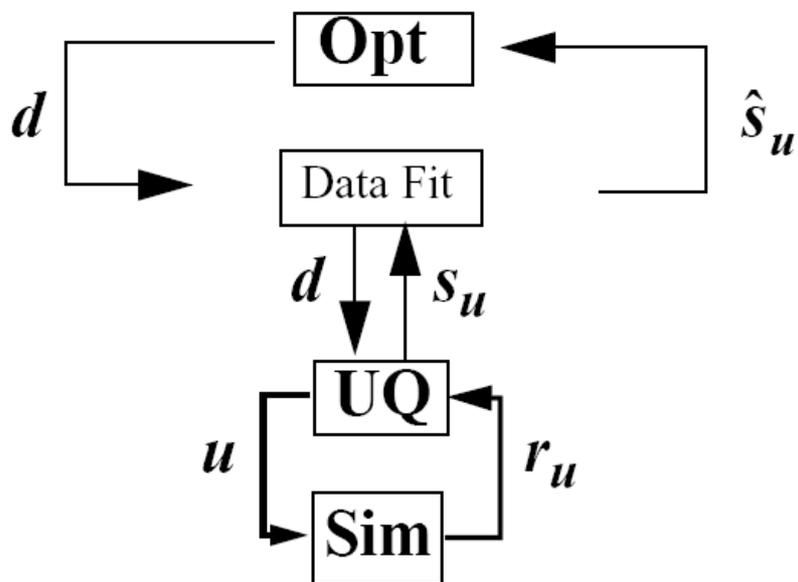


Figura 5.2: Metodologia camadas e aninhamento (Eldred et al, 2002).

Com esta metodologia é possível realizar estudos de otimização em reservatórios de petróleo, sem precisar calcular as derivadas do problema real, e considerando incertezas nas propriedades petrofísicas.

A seguir é apresentado um fluxograma de processo de otimização sob incertezas aplicado neste trabalho:

1. Um número de amostras de vazões nos poços numa região de confiança é obtido utilizando o método LCVT.
2. Para cada amostra um processo de propagação de incertezas é desenvolvido, retornando o VPL esperado.
3. Obtidas as amostras com suas respostas, um modelo substituto é gerado na região de confiança.
4. Um processo de otimização utilizando programação quadrática seqüencial é desenvolvido no modelo substituto.
5. É calculada a resposta no modelo de alta fidelidade da variável de controle ótima encontrada no passo 4.
6. A convergência do processo é verificada.
7. A região de confiança é modificada, de acordo com um processo de verificação entre os valores do modelo real e do modelo substituto.
8. Retorne para o passo 1.

5.4 Estudo de Caso – Injeção de Água em Reservatório com 3 poços

5.4.1 Caso 1 – 2 Variáveis de Controle e 1 Variável Incerta

Nesta etapa um estudo de otimização considerando incertezas é desenvolvido. O modelo do reservatório em estudo é similar aos estudos de casos nos capítulos anteriores. Na Figura 5.3 é visualizado o modelo do reservatório, as variáveis de controle serão as alocações dinâmicas das vazões nos poços produtores. O reservatório encontra-se sob injeção de água, e tem produção em regime topado, ou seja, a plataforma produz com vazão pré-estabelecida constante de líquidos (óleo e água). Neste problema é considerada a incerteza referente ao campo de permeabilidades.

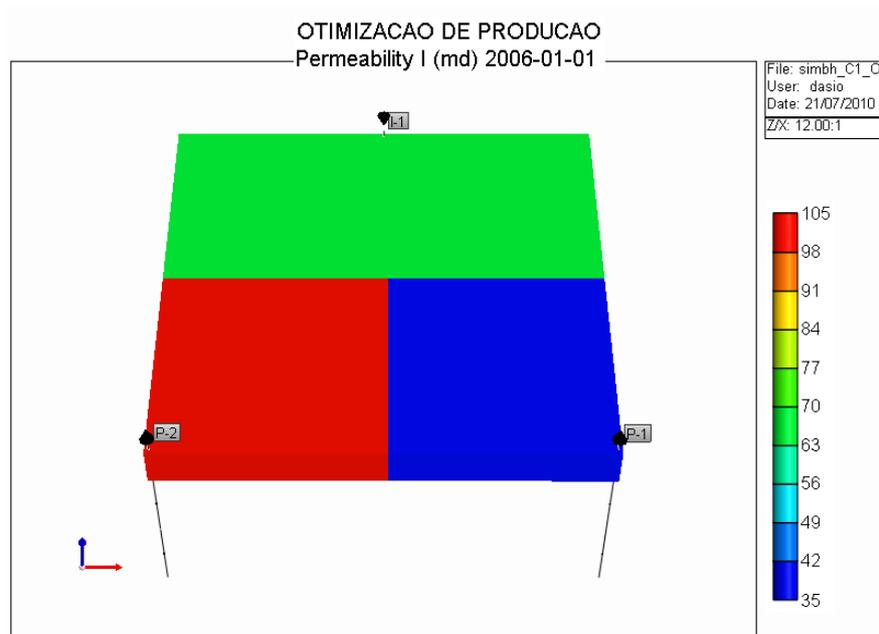


Figura 5.3: Modelo do reservatório sob injeção de água.

O reservatório produz por um período de 16 anos. O campo de permeabilidades permanece com 3 regiões de permeabilidades constantes. Na região verde é definido um valor que será considerado como valor base, e nas outras regiões (vermelho e azul) existem contrastes de 1,5 e 0,5 vezes o valor base. O reservatório possui uma área de $510 \times 510 \text{ m}^2$, com espessura de 4 m, sendo modelado com uma malha de $51 \times 51 \times 1$.

Como apresentado anteriormente existe apenas uma variável incerta, está variável é a permeabilidade base (região verde na Figura 5.3). Para esta foi admitido uma função de distribuição de probabilidade log-normal com um valor médio de 70 mD e desvio padrão de 21 mD.

A etapa de propagação de incertezas é executada com o método de caos polinomial, sendo o mesmo com a ordem de expansão 2. Os coeficientes da expansão foram calculados por quadratura numérica de ordem 3.

A otimização foi realizada com a estratégia SAO, onde nas regiões de confiança foram utilizados modelos substitutos por Krigagem. Os modelos substitutos foram construídos com a técnica de amostragem LCVT.

As duas variáveis de otimização são as vazões nos poço produtor 1 em dois ciclos de controle (GP1_1 e GP1_2). Ciclo de controle é considerado como um intervalo de tempo durante a produção do reservatório com um controle de vazão especificado. Neste problema a alocação da vazão no poço 2 é o complemento da vazão no poço 1 e que as duas soma das duas seja 100%, os poços produtores fazem parte de uma plataforma que trabalha em regime topado. A primeira variável de controle é a alocação da vazão no poço produtor 1 nos primeiros 6 anos, a segunda variável é a alocação da vazão também no poço 1 nos últimos 10 anos.

O Poço injetor possui vazão de água constante de 44 m³/dia, os dois poços produtores possuem restrição de vazão máxima de 9 m³/dia , sem restrições de BHP e corte de água. A plataforma (Grupo com os dois poços produtores) tem uma restrição de vazão de 12 m³/dia.

Resultados

	GP1_1 (%)	GP1_2 (%)	E (VPL) * 10 ⁵ (U\$\$)
Valor inicial	50.0	50.0	5.073
Valor ótimo	25.0	70.0	5.186

Tabela 5.1: Valor inicial e resultado da otimização sob incerteza.

Os resultados mostram que o valor esperado de VPL é máximo, quando o poço 1 opera com 25% da vazão da plataforma nos primeiros 6 anos, e com 70% no período restante.

5.4.2 Caso 2 – 2 Variáveis de Controle e 10 Variáveis Incertas

O segundo caso de estudo utilizando metodologias de otimização é um problema de reservatório novamente com 1 poço sob injeção de água e 2 poços produtores. O reservatório possui uma área de 510 x 510 m², com espessura de 4 m, sendo modelado com uma malha de 51 x 51x 1.

Foram geradas 1000 possíveis realizações para o campo de permeabilidades que permitem a obtenção da matriz de covariância numericamente. As realizações foram criadas utilizando o procedimento descrito na seção 4.2. Na Figura 5.4 e 5.5 são visualizadas 4 realizações do conjunto de 1000 possíveis, na primeira figura as realizações estão na escala real, já na segunda na escala logarítmica.

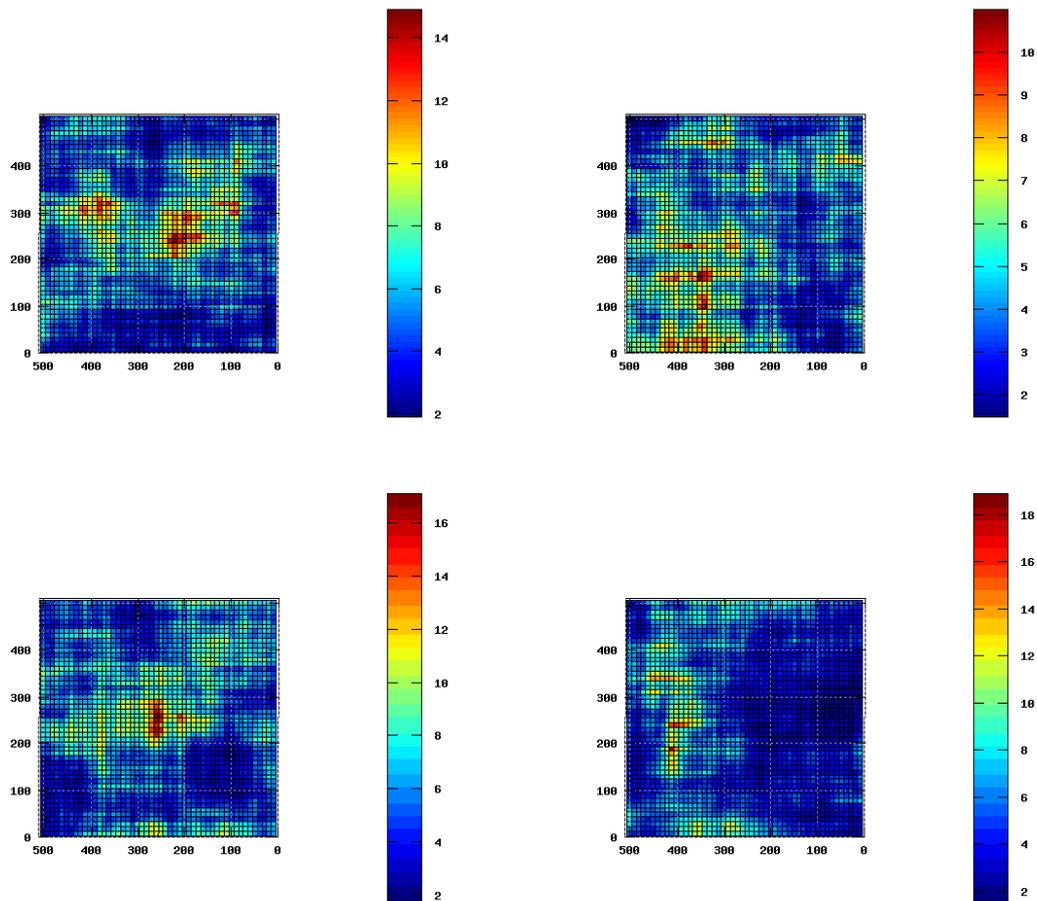


Figura 5.4: Realizações do campo de permeabilidades na escala real.

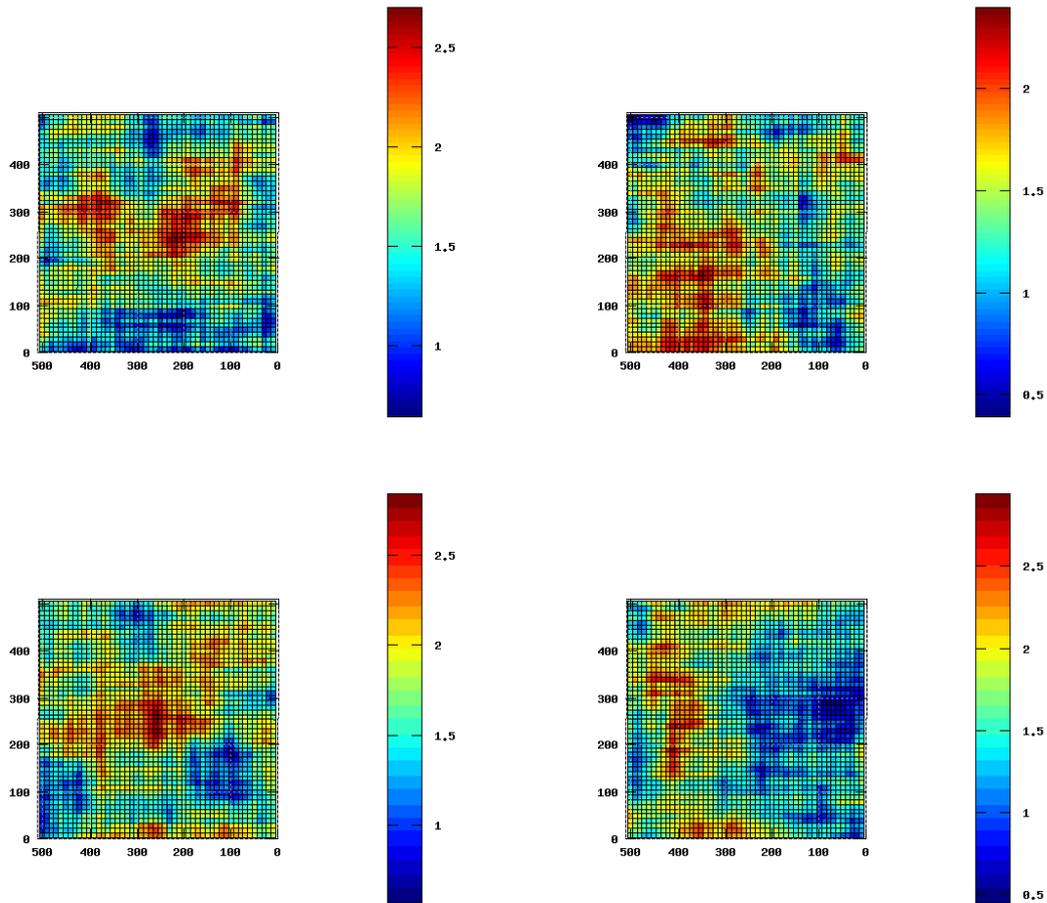


Figura 5.5: Realizações do campo de permeabilidades em escala logarítmica.

O tempo de produção do reservatório é de 24 anos. Os dois poços produtores fazem parte de uma plataforma que operam sempre em regime topado com uma vazão de líquidos de $6 \text{ m}^3/\text{dia}$.

A função objetivo do problema de otimização é novamente o VPL (equação 1.4), e as variáveis de projeto são as alocações dinâmicas de vazão de líquido nos poços produtores que possuem os limites de 25% e 75%. Dois intervalos de tempo de produção do reservatório (ciclos de controle) são utilizados, o primeiro intervalo é de 8 anos e o segundo com os 16 anos restantes.

Inicialmente foi realizado um estudo de otimização determinística, onde uma das possíveis realizações foi escolhida (Figura 5.6).

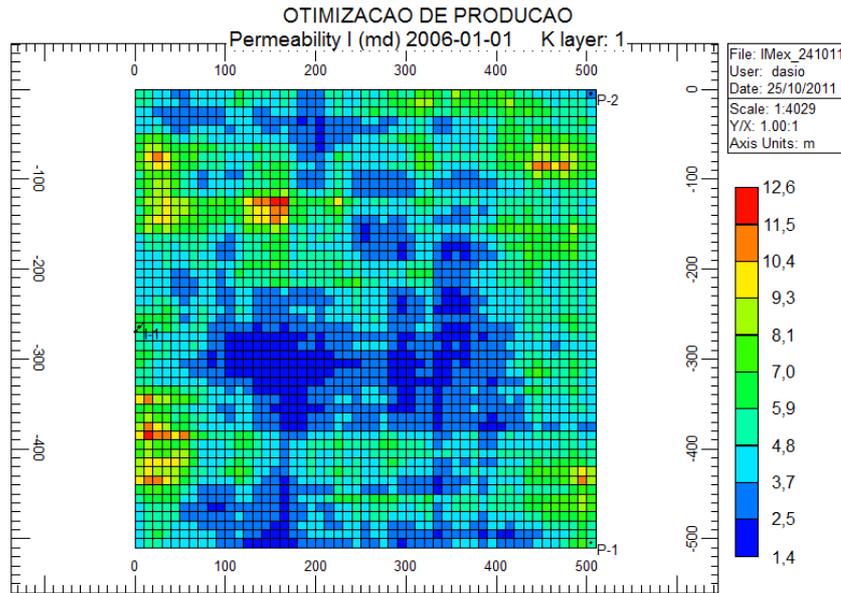


Figura 5.6: Realização escolhida para estudo de otimização determinística.

A otimização determinística foi realizada com a estratégia SAO, onde nas regiões de confiança foram utilizados modelos substitutos por Krigagem. Os modelos substitutos foram construídos com o método de amostragem LCVT. Na Tabela 5.2 são apresentados os resultados da otimização.

Resultados

	GP1_1 (%)	GP1_2 (%)	VPL * 10 ⁵ (U\$\$)
Valor inicial	75.0	25.0	2.385
Valor ótimo	26.4	70.7	2.510

Tabela 5.2: Valor inicial e resultado da otimização para o caso 2 (otimização determinística).

A Tabela mostra que o VPL é máximo quando o poço 1 opera com 26.4% no intervalo de tempo 1 (8 anos) e com 70.7 % no intervalo 2 (16 anos restantes).

Na Figura 5.7 temos as curvas de produção acumulada de óleo e água para os casos inicial e otimizado.

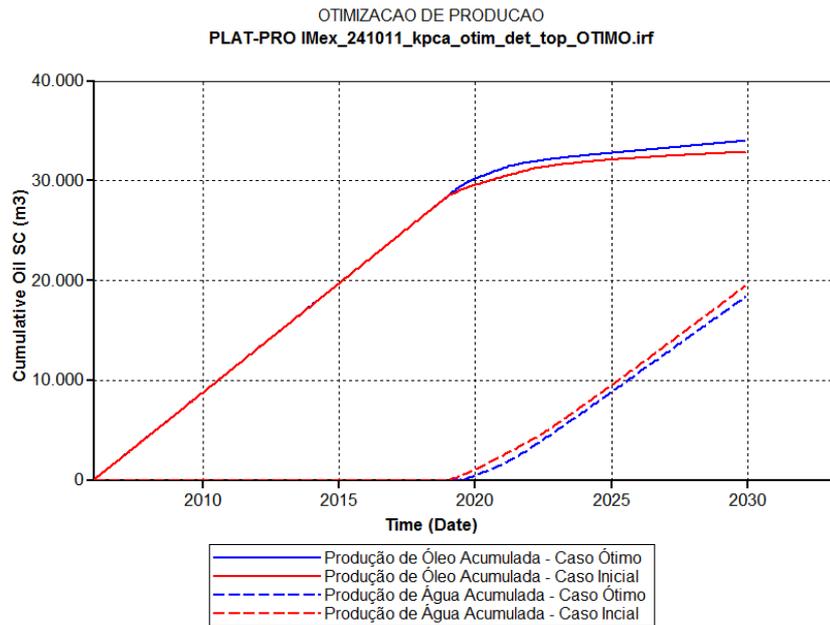


Figura 5.7: Curvas de produção acumulada de óleo e água para os casos inicial e otimizado.

As vazões de líquido iniciais nos poços produtores em cada intervalo de tempo são visualizadas na Figura 5.8. Na Figura 5.9 são visualizadas a vazões para o caso ótimo.

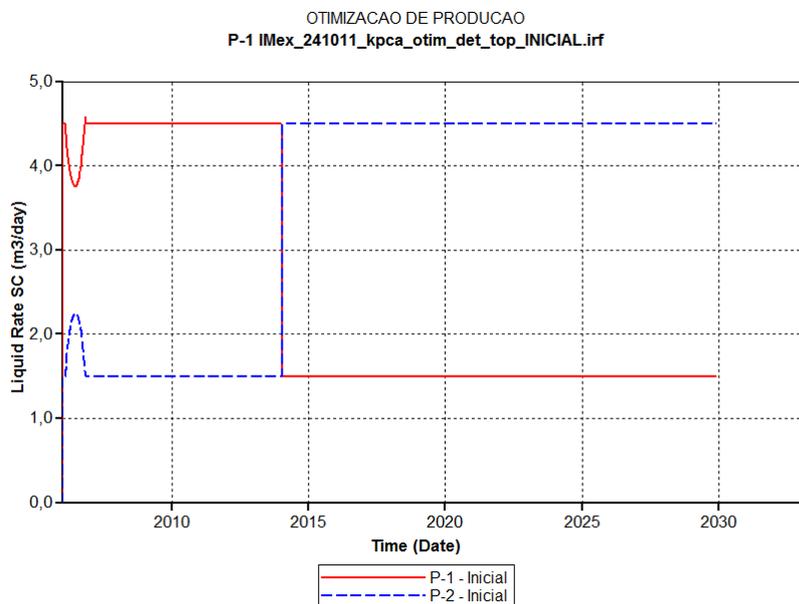


Figura 5.8: Curvas de vazões de líquidos nos poços produtores para o caso inicial.

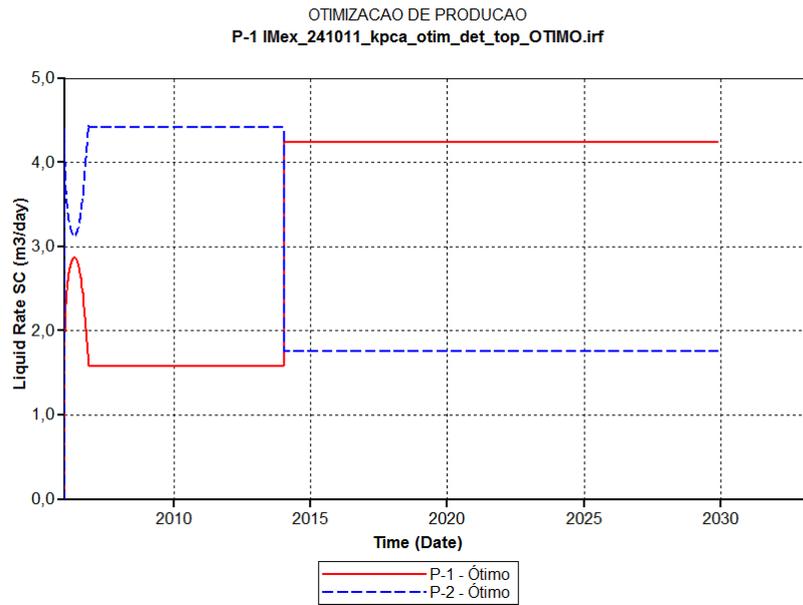


Figura 5.9: Curvas de vazões de líquidos nos poços produtores para o caso ótimo.

A Figura 5.10 mostra os cortes de água para os casos inicial e otimizado.

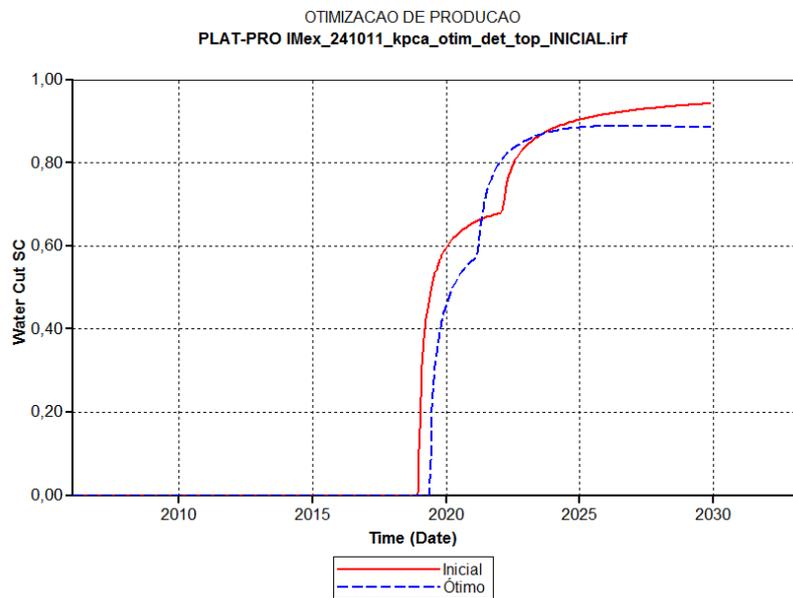


Figura 5.10: Cortes de água para os casos inicial e otimizado.

Os resultados da otimização determinística mostram um acréscimo no VPL de 5,5% no caso otimizado quando comparado com as vazões iniciais. Esta melhora deve-se a uma maior produção de óleo e a uma menor produção de água, além do retardamento da produção de água, como pode ser visto nas Figuras 5.7 e 5.10. Com relação ao custo computacional, foram necessárias 72 simulações do Imex, executadas em paralelo com 6 núcleos. A estratégia SAO executou 12 iterações até chegar à solução ótima.

Na segunda etapa foi realizado um estudo de otimização considerando as incertezas no campo de permeabilidades. As 1000 possibilidades são consideradas utilizando a metodologia KPCA linear com 10 componentes principais. A metodologia foi apresentada no capítulo 4. Normalmente, uma quantidade de componentes principais cujo seus respectivos autovalores produzem soma acumulada normalizada na ordem de 0,70 é uma escolha razoável. Neste caso a função objetivo é o valor esperado do VPL. A otimização sob incerteza foi realizada com a metodologia camadas e aninhamento, onde na etapa de otimização foram usados modelos substitutos gerados por Krigagem e a geração das amostras pela técnica LCVT. Na etapa de propagação de incertezas foi utilizada a expansão em caos polinomial com ordem 2, onde os coeficientes da expansão foram calculados por regressão linear. Na tabela 5.3 são apresentados os resultados da otimização.

Resultados

	GP1_1 (%)	GP1_2 (%)	E (VPL) * 10 ⁵ (U\$\$)
Valor inicial	75.0	25.0	2.746
Valor ótimo	75.0	40.5	2.802

Tabela 5.3: Valor inicial e resultado da otimização para o caso 2 (otimização estocástica).

As vazões ótimas no poço 1 foram de 75% na intervalo 1 e de 40,5% no intervalo 2. É importante observar que o resultado da otimização sob incerteza leva em consideração as 1000 possíveis realizações. Este tipo de otimização apresenta, apesar de um

aumento no custo computacional, resultados mais consistentes quando comparado com casos de otimização determinística onde não se sabe qual o verdadeiro campo de permeabilidades. Com relação ao custo computacional, neste caso de otimização estocástica foram necessárias 4572 simulações do Imex, executadas em paralelo com 6 núcleos. A estratégia SAO executou 6 iterações até chegar à solução ótima.

Como forma de verificar o resultado da otimização sob incerteza, o método de Monte Carlo foi utilizado para calcular o VPL com as vazões ótimas controladas, ou seja, o VPL esperado é calculado para um número especificado de realizações do campo de permeabilidades (amostras). Abaixo, a Tabela 5.4 apresenta os valores esperados (E) e desvios padrões (S) obtidos com o procedimento proposto e para o método de Monte Carlo (MC) calculados para o conjunto de 1000 e 2000 campos de permeabilidades gerados com a expansão de K-L. Na mesma tabela também é mostrado o resultado para um estudo de propagação de incertezas utilizando a expansão em caos polinomial (PCE – *Polynomial Chaos Expansion*), onde pode ser verificada a precisão de expansão polinomial (132 simulações) quando comparada ao método de Monte Carlo (1000 e 2000 simulações). Estes resultados são para as vazões ótimas obtidas no processo de otimização sob incerteza.

	PCE	MC – 1000	MC – 2000
E(VPL) * 10 ⁵ (U\$\$)	2.802	2.796	2.793
S (VPL) * 10 ⁵ (U\$\$)	0.201	0.196	0.202

Tabela 5.4: Valor esperado e desvio padrão do VPL para estudos de propagação de incertezas.

Os resultados de VPL esperado e desvio padrão apresentados na Tabela 5.4 mostram a precisão da expansão em caos polinomial comparada o método de Monte Carlo. É importante enfatizar que na expansão polinomial foram necessárias 132 simulações no modelo de alta fidelidade, enquanto no método de Monte Carlo foram respectivamente 1000 e 2000 simulações.

Com os resultados obtidos com a otimização sob incerteza, um estudo de verificação da robustez da solução foi realizado [Van Essem et al, 2006]. Quatro realizações

integrantes do conjunto das mil iniciais foram escolhidas aleatoriamente. Para cada realização foi conduzida uma otimização determinística específica da mesma forma que já foi realizada neste capítulo. Em seguida, as vazões ótimas obtidas no processo de otimização sob incerteza foram alocadas em cada uma das 4 realizações e posteriormente o VPL foi calculado para cada uma delas. Na etapa final os valores de vazões ótimos determinísticos obtidos em cada uma das 4 realizações foram alocados para as outras 3 realizações em estudo. Por exemplo: as vazões ótimas obtidas na realização 1 foram alocadas nas realizações 2, 3 e 4, este processo foi repetido para todas as realizações 2, 3 e 4, o VPL foi então calculado para cada caso. Nas Tabelas 5.5 e 5.6 são apresentados todos os resultados do processo de verificação da otimização sob incerteza. A Tabela 5.5 apresenta os resultados obtidos para o processo de otimização determinística em cada realização escolhida, como também o resultado obtido no processo de otimização sob incerteza. Em negrito os resultados obtidos no processo de otimização determinística. A Figura 5.11 apresenta os resultados da Tabela 5.6 em forma de gráfico, com o objetivo de tornar mais claros os resultados.

	Otimização sob incerteza	Realização 1 (Caso C1)	Realização 2 (Caso C2)	Realização 3 (Caso C3)	Realização 4 (Caso C4)
Vazões (%)	[75.0, 40.5]	[0.26, 0.70]	[0.25, 0.75]	[0.67, 0.59]	[0.72, 0.31]
VPL * 10 ⁵ (U\$\$)	2.802	2.510	2.964	3.059	2.902

Tabela 5.5: Vazões e VPL ótimos para o processo de otimização determinística e otimização sob incerteza.

	Realização 1	Realização 2	Realização 3	Realização 4	Valor Médio
VPL Caso OOU * 10 ⁵ (U\$)	2.460	2.850	2.990	2.877	2.794
VPL Caso C1 * 10 ⁵ (U\$)	2.510	2.506	3.058	2.664	2.685
VPL Caso C2 * 10 ⁵ (U\$)	2.385	2.964	2.802	2.893	2.761
VPL Caso C3 * 10 ⁵ (U\$)	2.476	2.594	3.059	2.728	2.714
VPL Caso C4 * 10 ⁵ (U\$)	2.418	2.935	2.888	2.902	2.786

Tabela 5.6: Resultados para o processo de verificação da otimização sob incerteza.

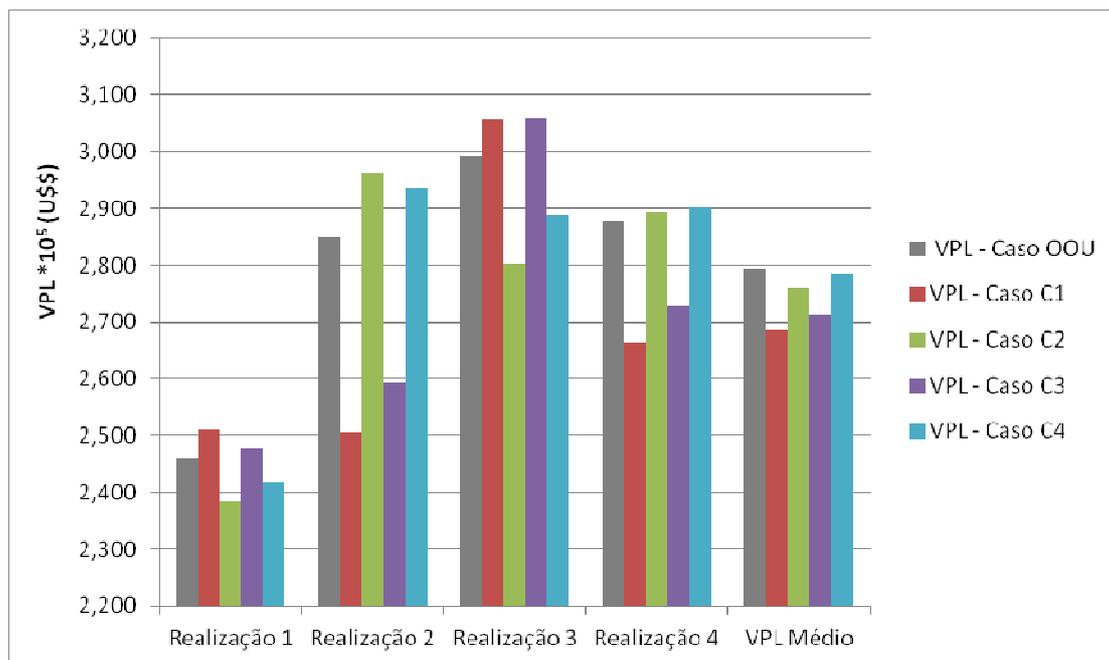


Figura 5.11: Gráfico dos VPL referentes à Tabela 5.6.

Os resultados apresentados nas Tabelas 5.4 e 5.6, com também na Figura 5.11 representam a robustez do resultado obtido no processo de otimização sob incertezas. Como esperado, os valores do VPL referentes à otimização determinística são os

melhores casos para cada realização. Entretanto, em problemas de reservatórios reais a realização verdadeira do campo não é conhecida, inviabilizando a otimização determinística. Os valores de VPL obtidos com as vazões oriundas da otimização sob incerteza (OUU) apresentam bons resultados, principalmente quando comparados com os resultados obtidos a partir das vazões resultantes do processo de otimização determinística realizada em cada realização.

As vazões obtidas no processo de otimização sob incerteza, quando alocadas em cada uma das 4 realizações escolhidas (VPL – OUU), produzem um VPL médio de 2.794×10^5 U\$\$\$. Este valor é maior que os valores de VPL médios obtidos nos casos C1, C2, C3 e C4 usando os controles específicos das outras realizações. É importante também verificar no caso de qualquer uma das quatro realizações fosse a realização verdadeira do reservatório, as vazões de controle ótimas obtidas no processo de otimização sob incerteza em cada caso produziriam uma estimativa satisfatória do VPL. O método OUU utilizado evita que os piores casos de vazão de controle sejam os escolhidos. Isto aconteceria, por exemplo, se as vazões da otimização fossem calculadas deterministicamente sobre a realização 2 e a realização verdadeira do reservatório fosse a realização 1, como mostrado na Figura 5.11. Nesta situação, o VPL resultante seria inferior quando comparado ao VPL produzido pelas vazões OUU sobre a realização 1. Esta mesma idéia é aplicada para as realizações 2, 3 e 4 (Figura 5.11).

Capítulo 6

Ajuste de Histórico

6.1 Introdução

Na engenharia e gerenciamento de reservatórios, freqüentemente decisões precisam ser realizadas tomando como base dados obtidos através de simulação numérica de reservatórios. Várias propriedades do reservatório, tais como, permeabilidade e porosidade precisam ser conhecidas para realização de simulações numéricas precisas, o que não acontece na maioria dos casos. Na realidade, estimativas iniciais das propriedades do reservatório são desenvolvidas através de dados que vem de poços, que muitas vezes são separados a centenas ou milhares de metros de distância. É importante levar em consideração que a perfuração de um poço tem um alto custo, e nos estudos iniciais poucos poços são perfurados. Existem também as medições indiretas, como a sísmica que fornecem estimativas das propriedades em todo o campo.

Neste capítulo será apresentada uma metodologia para realização de ajuste de histórico em problemas de reservatório de petróleo. Ajuste de histórico é um problema inverso que tem como objetivo a calibração de modelos de simulação numérica de reservatórios de acordo com histórico de dados de produção observados. O ajuste de histórico é uma etapa necessária no processo de gerenciamento de reservatórios, principalmente para fazer estimativas de produção através de extrapolação de dados, como também na atualização de modelos para estudos de gerenciamento.

A relação entre as propriedades do modelo de reservatório (m), e os dados observados (d) ou qualquer saída do modelo é descrita de acordo com a equação 6.1.

$$g(m) = d \quad (6.1)$$

Quando as propriedades do modelo são conhecidas, simulações numéricas podem ser realizadas diretamente. Este tipo de problema é conhecido como problema direto. Quando as propriedades m não são totalmente conhecidas, estas são obtidas através dos dados observados (d_{obs}). Agora temos o problema inverso (Oliver et al, 2008; Tarantola, 2005) que pode ser formulado de acordo com a equação 6.2. Onde ϵ são os erros relacionados aos dados observados.

$$d_{obs} = g(m) + \epsilon \quad (6.2)$$

Os procedimentos tradicionais de ajuste de histórico são o ajuste manual e o ajuste assistido. O ajuste manual é uma metodologia de tentativa e erro, onde os atributos incertos são ajustados manualmente com objetivo de alcançar um modelo o mais próximo possível do reservatório real.

No ajuste assistido o processo de ajuste de histórico é automatizado. Com este método temos vários benefícios, tais como, mudanças automáticas nos arquivos de entrada do simulador de reservatório, execução do simulador, análises da função objetivo. (Maschio e Schiozer, 2003).

O ajuste de histórico automático pode ser conduzido através de um processo de otimização, portanto uma função objetivo precisa ser formulada. Na literatura encontramos diferentes formas de função objetivo para o problema de ajuste de histórico (Filho, 2006; Afonso et al, 2010; Carmo, 2010). Como o ajuste é sempre realizado considerando comparações entre dados observados e dados calculados por simuladores, as funções objetivos geralmente são formadas através de métrica dos erros entre os dados observados e calculados. Na Figura 6.1 temos um exemplo com curvas representado o processo de ajuste de histórico.

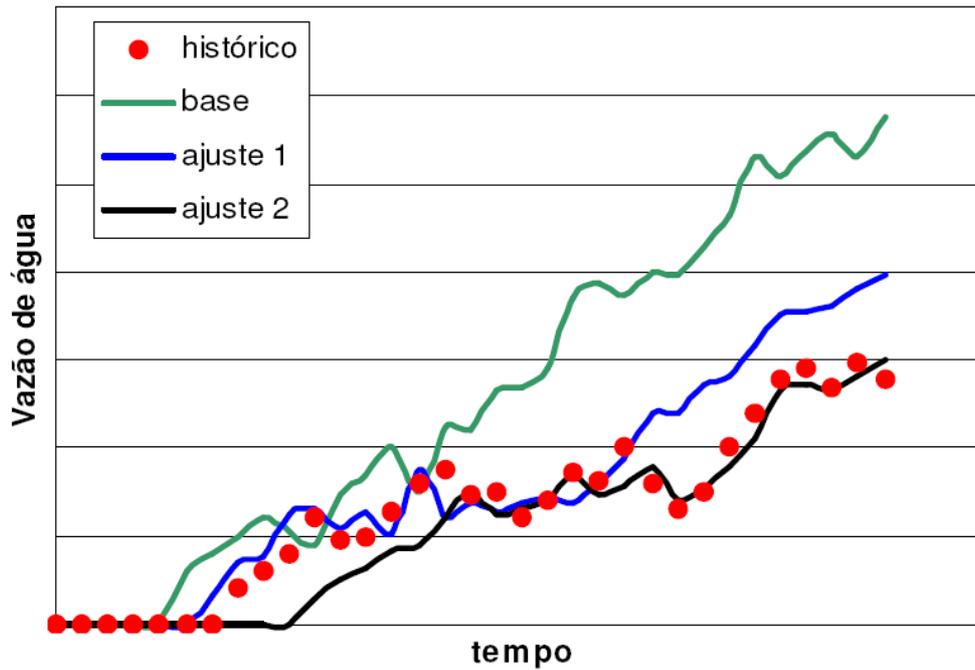


Figura 6.1: Curvas representando o processo de ajuste de histórico (Moura Filho, 2006).

O pontos vermelhos indicam os dados observados, a curva verde é o caso base inicial (estimativa inicial), já as curvas de ajuste 1 (azul) e 2 (preta) são dois ajustes possíveis. No primeiro ajuste foram utilizados os dados observados na primeira metade do tempo, já o ajuste 2 utilizou os dados da segunda metade do tempo.

As funções objetivo utilizadas geralmente em problemas de ajuste de histórico estão relacionadas com as seguintes grandezas: vazões de produção, pressão nos poços, corte de água e índice de produtividade nos poços. Neste trabalho será realizado o ajuste no campo de permeabilidades do reservatório, e a função objetivo envolve as produções de óleo acumuladas nos poços, que claramente dependem do campo de permeabilidades, sendo estas as variáveis de projeto.

Um dos principais problemas relacionado às metodologias de ajuste de histórico é a multiplicidade de soluções, pois um número infinito de combinações de parâmetros pode fornecer respostas semelhantes (Leitão, 1997). Neste trabalho o campo de permeabilidades será ajustado e representado pela expansão de K-L. O processo de otimização

será realizado utilizando a técnica SAO cujos modelos substitutos são construídos a partir do ajuste de superfície por Krigagem.

6.2 Metodologias de Ajuste

A função objetivo utilizada neste trabalho para o desenvolvimento de ajuste de histórico é baseada nas diferenças da produção acumulada de óleo no tempo n entre a curva de produção observada e a curva de produção obtida pelo simulador.

É importante mencionar que a formulação do problema direto é $d = f(m)$, que no problema de reservatórios são as equações de saídas do simulador, não são apenas dependentes dos parâmetros do modelo, mas também das variáveis de estado \mathbf{x} (pressão, saturação, etc.) e das variáveis de controle \mathbf{u} (vazões nos poços, pressão de fundo de poço, etc.), logo $\mathbf{d} = f(\mathbf{x}^{n+1}, \mathbf{u}^n, \mathbf{m})$, onde n é o índice do passo de tempo.

O problema de ajuste de histórico é declarado da seguinte forma:

$$\min_{\mathbf{m}} \left[\sum_{n=0}^{N-1} L^n(x^{n+1}, u^n, \mathbf{m}) \right] \forall n \in (0, \dots, N-1)$$

Sujeito a:

$$\begin{aligned} g^n(x^{n+1}, x^n, u^n, \mathbf{m}) &= 0 \quad \forall n \in (0, \dots, N-1) \\ x^0 &= x_0 \quad (\text{Condições iniciais}) \\ \mathbf{m} &\in \text{Realizações do campo de permeabilidades} \end{aligned} \quad (6.3)$$

Considerando um problema de ajuste de histórico, o termo $L^n(x^{n+1}, u^n, \mathbf{m})$ é a função objetivo, que neste trabalho tem a seguinte forma:

$$L^n(x^{n+1}, u^n, \mathbf{m}) = \sum_{i=1}^{N_w} \left\{ f_i(x^{n+1}, u^n, \mathbf{m}) - d_{obs_i}^n \right\}^2 \quad (6.4)$$

Onde f_i é a produção acumulada de óleo no tempo n e no poço i obtida pelo simulador de reservatórios, e $d_{obs_i}^n$ é a produção acumulada de óleo observada no tempo n

e no poço i . A variável a ser encontrada é m , que neste trabalho será o campo de permeabilidades.

6.2.1 Aplicação Utilizando a Expansão de Karhunen-Loeve

Nesta etapa a expansão de K-L é utilizada. Usando as equações 6.3 e 6.4 juntamente com a expansão de K-L, é possível alcançar resultados aproximados do campo verdadeiro. A expansão de K-L também a parametrização do campo de permeabilidades, reduzindo o espaço probabilístico, pois são considerados poucos componentes principais para encontrar uma aproximação do campo verdadeiro. Como mostrado no capítulo 4, a expansão de K-L é função de um vetor de variáveis aleatórias não correlacionadas ξ , portanto uma vez calculados os autopares da matriz núcleo, o campo torna-se função de ξ . Agora a equação 6.3 fica da seguinte forma:

$$\min_m \left[\sum_{n=0}^{N-1} L^n(x^{n+1}, u^n, m(\xi)) \right] \forall n \in (0, \dots, N-1)$$

Sujeito a:

$$g^n(x^{n+1}, x^n, u^n, m(\xi)) = 0 \quad \forall n \in (0, \dots, N-1)$$

$$x^0 = x_0 \quad (\text{Condições iniciais}) \quad (6.5)$$

$m \in$ Realizações do campo de permeabilidades

Onde:

$$L^n(x^{n+1}, u^n, m(\xi)) = \sum_{i=1}^{N_w} \left\{ f_i(x^{n+1}, u^n, m(\xi)) - d_{obs_i}^n \right\}^2 \quad (6.6)$$

Portanto, as variáveis a serem otimizadas são ξ , estas apesar de serem não correlacionadas, produzem uma realização com a manutenção das características geológicas inseridas através da matriz de covariância C .

O método utilizado para a otimização do problema declarado nas Equações 6.5 e 6.6 é o método SAO, utilizando modelos substitutos locais por Krigagem. Esta metodologia foi apresentada no capítulo 5.

6.3 Estudos de Caso - Injeção de Água em Reservatório com 3 Poços

A metodologia de ajuste de histórico apresentada neste capítulo foi aplicada inicialmente a um caso de reservatório de petróleo sob injeção de água. Um esquema do reservatório é representado na Figura 6.2. O reservatório possui um poço injetor e dois poços produtores. Como no capítulo 4 as realizações foram criadas a partir de uma função de covariância conhecida pela equação 4.1 e o auxílio do pacote computacional de estatística do Matlab (Mathworks, 2001). Propositamente foram criadas duas regiões com diferentes valores médios de permeabilidade. A partir de um conjunto de 1000 permeabilidades geradas, uma delas foi considerada como caso verdadeiro ou observado. Na Figura 6.3 são mostradas algumas das realizações possíveis para o caso estudado. O campo de permeabilidades considerado como observado ou verdadeiro é visualizado na Figura 6.4.

Na primeira etapa dos estudos o campo de permeabilidades foi representado pela metodologia KPCA linear. Numa segunda etapa foi utilizada a metodologia KPCA não linear. O tempo de produção usado para o ajuste de histórico foi de 10 anos, sendo posteriormente realizada uma extrapolação dos dados em 6 anos. O reservatório possui uma área de $510 \times 510 \text{ m}^2$, com espessura de 4 m, sendo modelado com uma malha de $51 \times 51 \times 1$. O poço injetor opera com vazão máxima de $24 \text{ m}^3/\text{dia}$, enquanto os poços produtores operam com vazão máxima de $10 \text{ m}^3/\text{dia}$ e com BHP mínimo de 50 kgf/cm^2 .

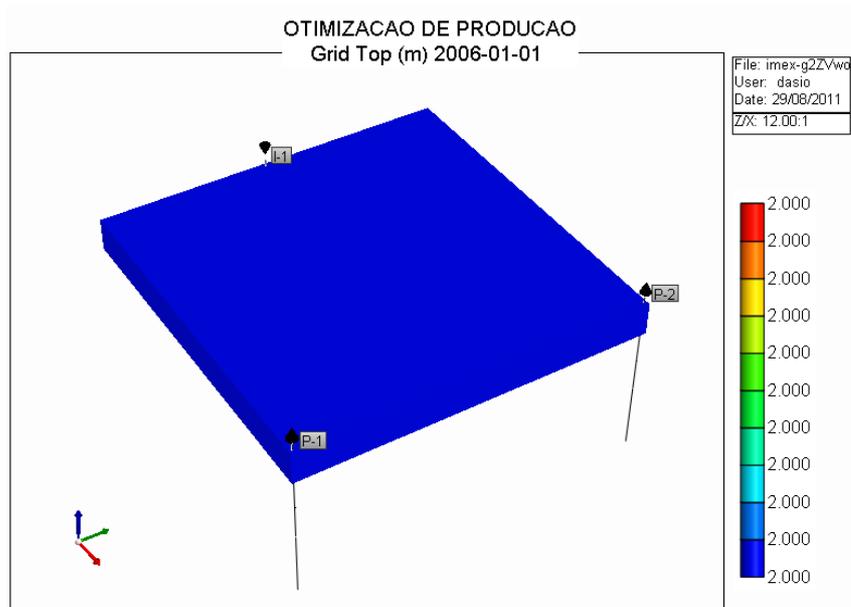


Figura 6.2: Modelo do reservatório para o estudo de caso.

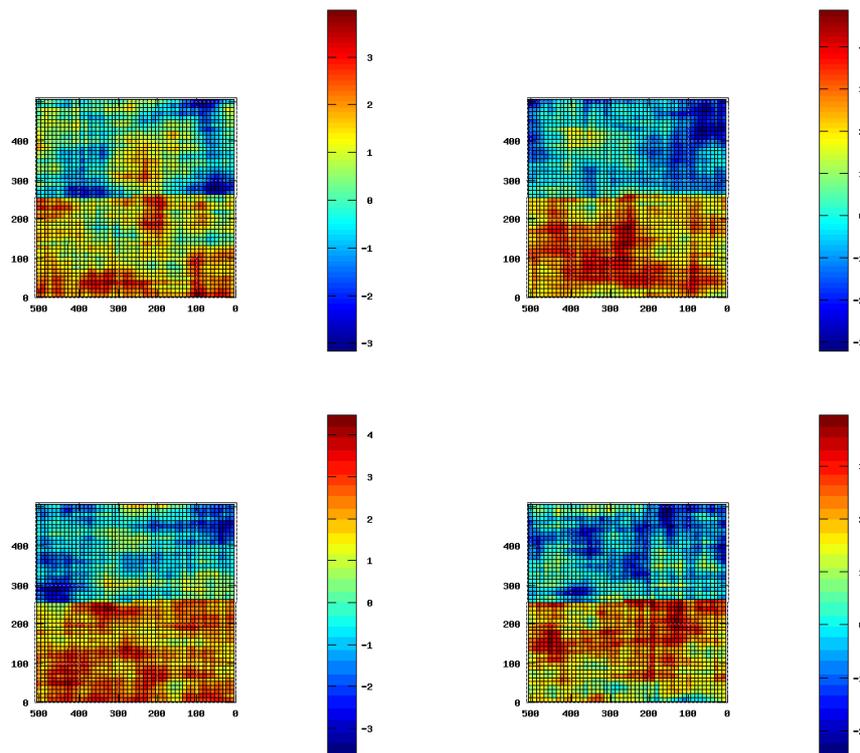


Figura 6.3: Realizações possíveis para o estudo de caso (escala logarítmica).

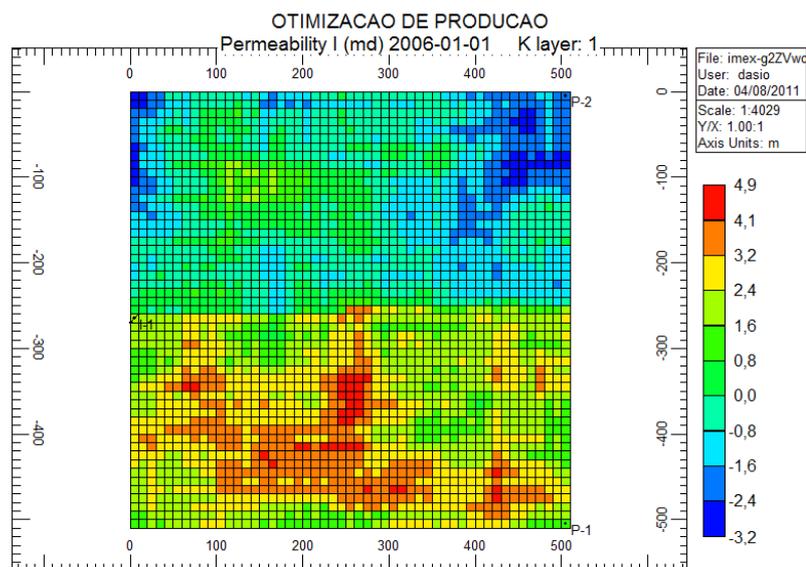


Figura 6.4: Realização escolhida como caso observado (escala logarítmica).

6.3.1 Ajuste Utilizando KPCA Linear

A partir das 1000 realizações iniciais, o campo de permeabilidades foi representado utilizando a metodologia KPCA Linear, considerando 10 componentes principais. A função objetivo é representada na equação 6.6.

Na Figura 6.5 são mostradas as curvas de produção acumulada de óleo, nas seguintes situações: caso observado, caso inicial e otimizado. No processo de ajuste de histórico, a curva verde é a produção relacionada à estimativa inicial do campo de permeabilidades. A curva azul é a produção do real observada do reservatório, e a curva vermelha é obtida utilizando o campo de permeabilidades calculado através do ajuste de histórico. Na Figura 6.6 é realizada uma extrapolação das curvas de produção acumulada apresentadas na Figura 6.5. Os campos de permeabilidades inicial e ajustado são visualizados nas Figuras 6.7 e 6.8.

Como pode ser vista na Figura 6.5, o ajuste de curvas foi satisfatório. Entretanto, como verificado nas Figuras 6.7 e 6.8, a realização ajustada apresenta campo de permeabilidade diferente do campo observado, principalmente na região central do campo, isto acontece devido a limitações da representação com a utilização da metodologia

KPCA linear. Para obtenção de campo com características mais próximas do campo observado será utilizada a metodologia KPCA não linear.

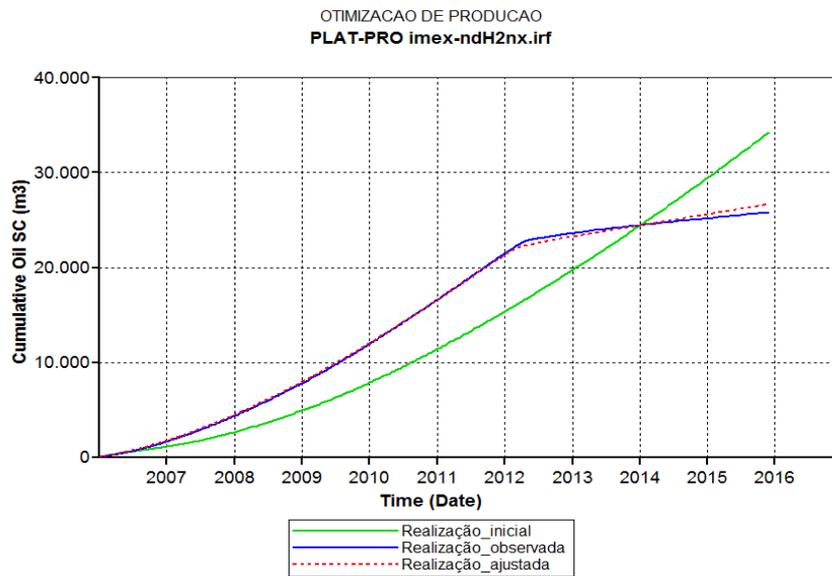


Figura 6.5: Curvas de produção acumulada de óleo obtidas no processo de ajuste de histórico.

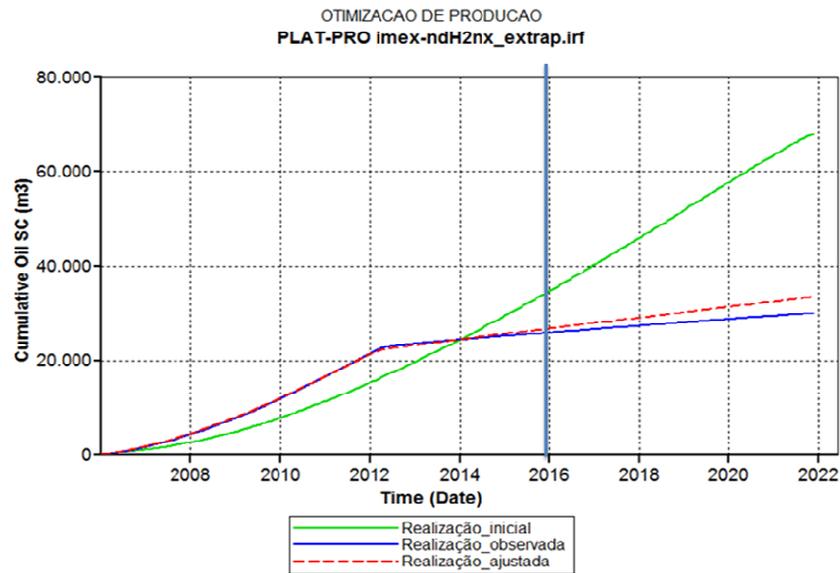


Figura 6.6: Extrapolação das curvas de produção acumulada de óleo obtidas no processo de ajuste de histórico.

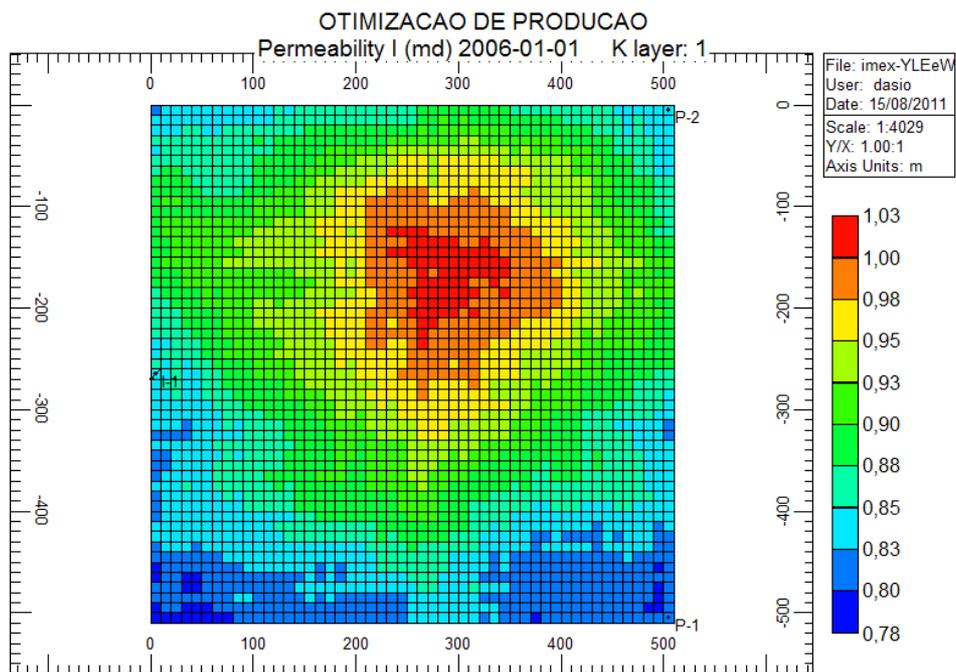


Figura 6.7: Estimativa inicial do campo de permeabilidades.

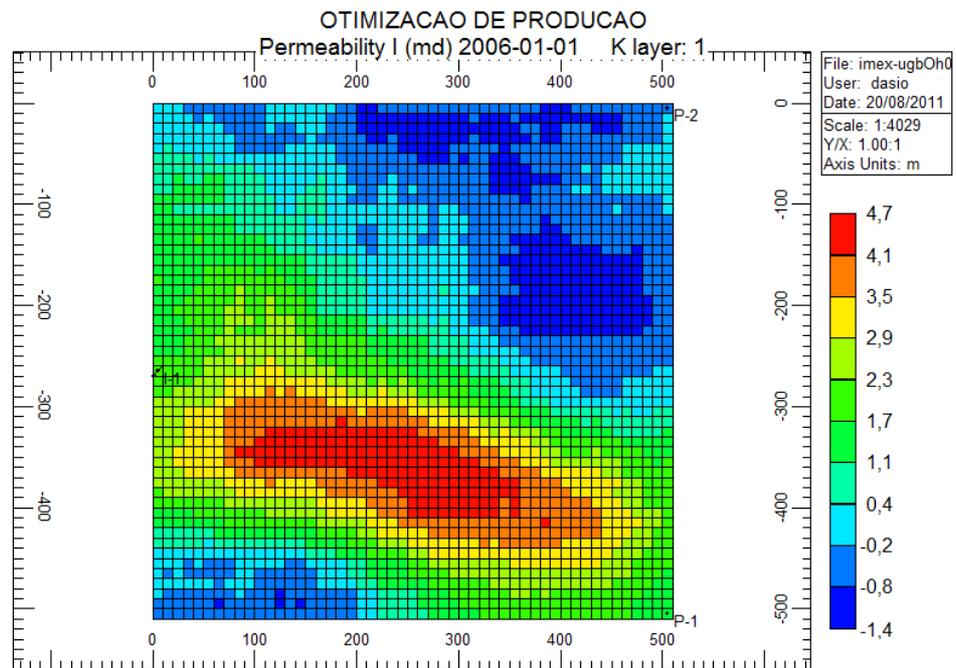


Figura 6.8: Campo de permeabilidades obtido com o processo de ajuste de histórico.

6.3.2 Ajuste Utilizando KPCA Não Linear

Nesta etapa, o campo de permeabilidades é representado utilizando a metodologia KPCA não linear. O modelo do reservatório é o mesmo utilizado na aplicação da metodologia KPCA linear. A função objetivo continua sendo representada na equação 6.6.

O estudo foi realizado utilizando 10 componentes principais. Na Figura 6.9 são mostradas as curvas de produção acumulada de óleo obtidas no processo de ajuste de histórico. Na Figura 6.10 é mostrado o caso de extrapolação das curvas, e nas Figuras 6.11 e 6.12 são mostradas as estimativas iniciais e ajustada do campo de permeabilidades. O campo observado é representado na Figura 6.4.

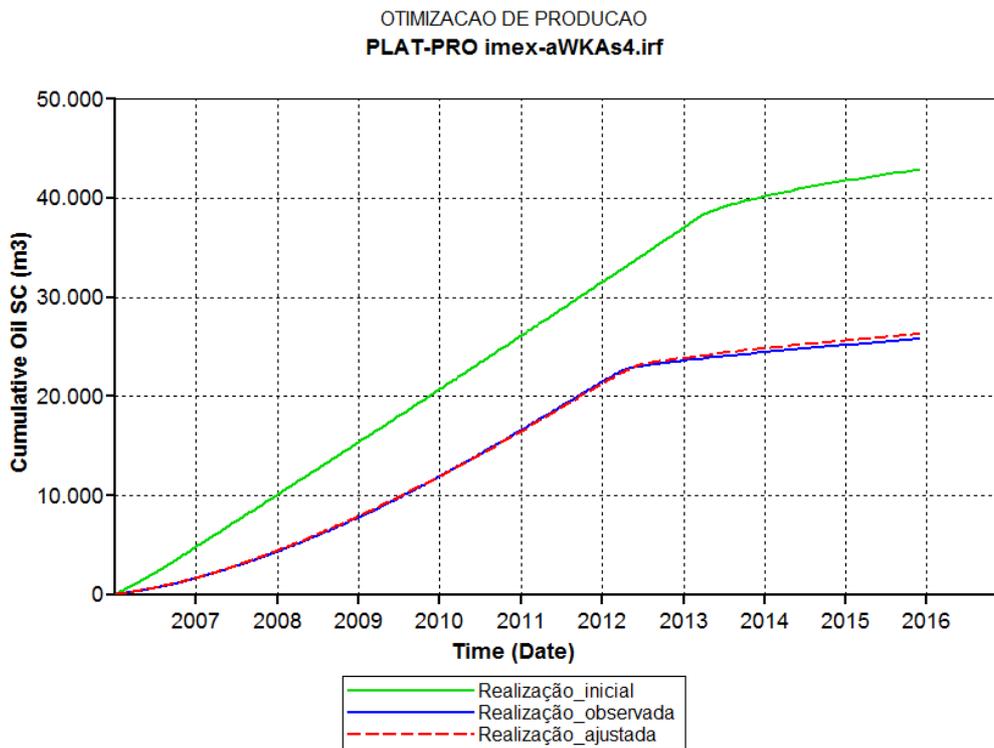


Figura 6.9: Curvas de produção acumulada de óleo obtidas no processo de ajuste de histórico.

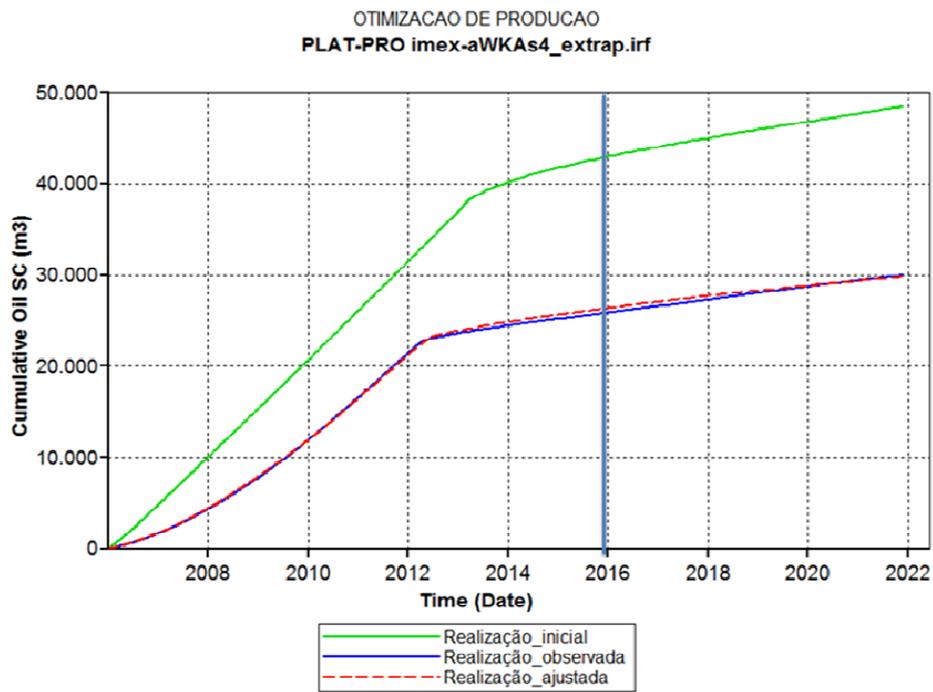


Figura 6.10: Extrapolação das curvas de produção acumulada de óleo obtidas no processo de ajuste de histórico.

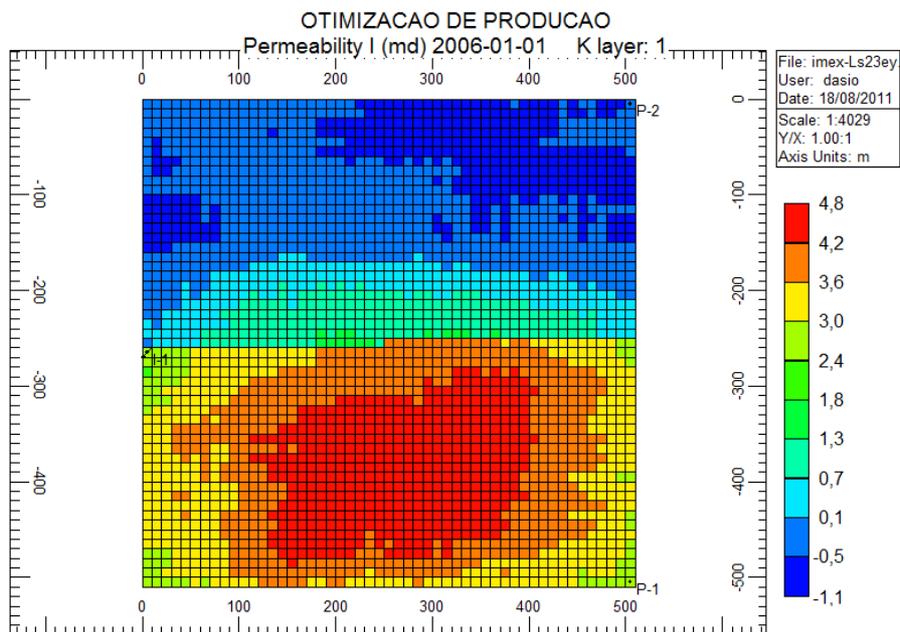


Figura 6.11: Estimativa inicial do campo de permeabilidades.

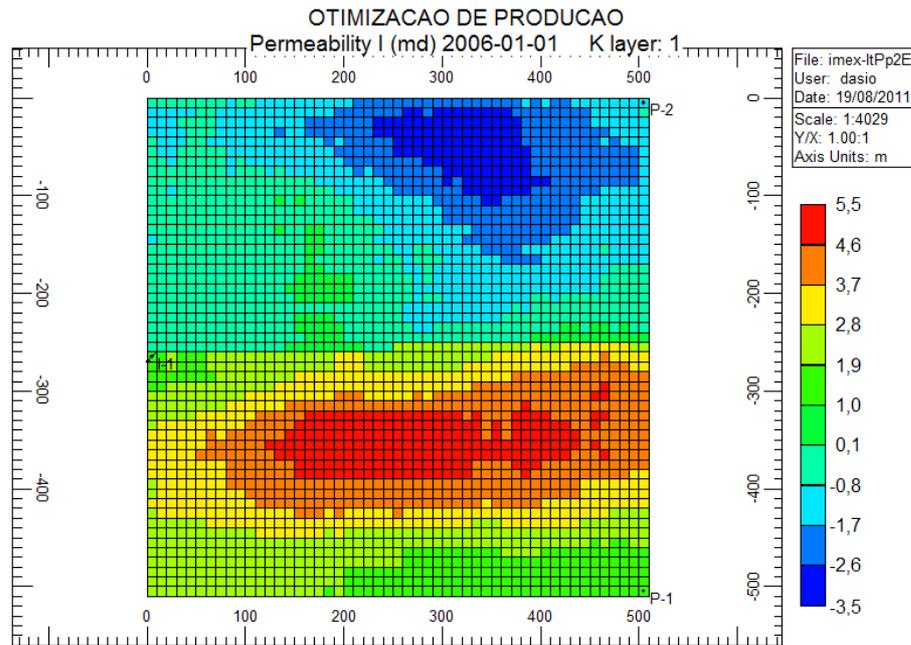


Figura 6.12: Campo de permeabilidades obtido com o processo de ajuste de histórico.

Com os resultados apresentados, a metodologia KPCA não linear em comparação com a metodologia KPCA linear, apresenta um campo de permeabilidades ajustado mais próximo do campo observado. Além da caracterização geológica que pode ser verificada visualmente, as curvas de extrapolação mostram que a metodologia KPCA não linear apresenta uma melhor aproximação do campo observado. É importante mencionar que o resultado final obtido com metodologia KPCA não linear foi alcançado com 11 iterações no método SAO (726 simulações do imex), enquanto o resultado obtido na KPCA linear precisou de 86 iterações (5676 simulações do imex). As simulações foram executadas em paralelo com a utilização de 6 núcleos.

Capítulo 7

Conclusões e Trabalhos Futuros

7.1 Conclusões

A pesquisa relacionada ao problema de otimização das vazões de produção em reservatórios de petróleo considerando incertezas, desenvolvida neste trabalho, mostrou-se claramente um problema de elevada complexidade. Os desafios neste campo são dos mais variados, passando pelo matemático, físico e computacional. Neste capítulo serão apresentadas as principais conclusões do trabalho, como também algumas sugestões para trabalhos futuros.

1. A utilização de modelos substitutos é uma alternativa viável computacionalmente para resolução de problemas de otimização quando as derivadas do problema não estão disponíveis ou necessitam de um alto custo computacional para serem obtidas. É importante mencionar que no caso de otimização sob incerteza a viabilidade computacional depende da utilização computação paralela, ou seja, vários núcleos de processadores são necessários.
2. No estudo relacionado às metodologias de amostragem para construção de modelos substitutos, LCVT foi à metodologia que apresentou melhores resultados. Também foram estudadas as metodologias QMC e LHS.

3. Entre as metodologias de modelos substitutos estudadas, tais como: Krigagem, Processo Gaussiano e MARS. A Krigagem foi quem apresentou os melhores resultados.
4. Os resultados dos estudos de propagação de incertezas com a metodologia KPCA mostram considerável ganho em eficiência computacional, devido à redução do espaço probabilístico do campo estocástico.
5. A utilização da expansão em caos polinomial mostrou ser eficiente principalmente quando comparada com a técnica de Monte Carlo.
6. A metodologia KPCA não linear consegue representar campos estocásticos mantendo suas características geológicas, entretanto, quanto maior a complexidade geológica maior será o grau do polinômio utilizado para gerar a matriz núcleo.
7. A metodologia de otimização considerando incertezas, com modelos substitutos e KPCA quando aplicada para problemas de ajuste de histórico alcançou resultados consistentes. O ajuste quando realizado com a metodologia KPCA não linear conseguiu capturar as características geológicas do campo de permeabilidades.
8. A metodologia de otimização considerando incertezas apresentou resultados robustos, ou seja, os controles obtidos no processo apresentam certa imunidade aos casos que produzem valores insatisfatórios para o VPL.

7.2 Trabalhos Futuros

No desenvolvimento deste trabalho de pesquisa foi percebido que algumas etapas precisam de um estudo mais avançado, além da necessidade de realizar novos testes, principalmente em reservatório com características mais próximas de situações reais. As principais sugestões para trabalhos futuros são apresentadas abaixo:

1. Existe a necessidade de utilizar as metodologias desenvolvidas utilizando realizações do campo de permeabilidade geradas por técnicas geoestatísticas (Deutsch e Journel, 1997).
2. As metodologias desenvolvidas precisam ser aplicadas em problemas de reservatório reais.
3. As metodologias apresentadas podem ser utilizadas para o desenvolvimento da técnica de ciclo fechado.
4. Uma importante sugestão é a aplicação em problemas em que a plataforma não está topada, além da utilização de outras variáveis de projeto no processo de otimização, tais como pressão de fundo de poço nos poços produtores e injetores.
5. Desenvolvimento de pesquisa para inclusão da incerteza na área da análise econômica do reservatório.
6. Aplicar as metodologias apresentadas em outros métodos de recuperação, tal como injeção de polímeros.

7. Outras funções objetivo podem ser utilizadas para desenvolvimento de ajuste de histórico, tais como, funções em que as variáveis são corte de água ou VPL.

Bibliografia

ABOU-KASSEM, J.H., FAROUQ, S. M., ISLAM, M. R. *Petroleum Reservoir Simulation: A basic Approach*, Gulf Publishing Company, 2006.

ADAMSON, G., CRICK, M., GANE, B., GURPINAR, O., HARDIMAN, J. POTING, D. *Simulation Throughout the Life of a Reservoir*; Oilfield Review; Schlumberger, 1996.

AFONSO, S. M., HOROWITZ, B., LIRA JUNIOR, J. D., CARMO , A., CUNHA, J., WILLMERDORF, R. *Comparison of Surrogate Building Techniques for Engineering Problems*. XXIX Cilamce, 2008.

AFONSO, S. M., WILLMERDORF, R., CARMO , A., HOROWITZ, B., LIRA JUNIOR, J. D. *Surrogate Based Optimization Applied To History Matching In Petroleum Reservoir Engineering*. Association for Structural and Multidisciplinary Optimization in the UK (ASMO-UK), 2010.

ANP - AGÊNCIA NACIONAL DE PETRÓLEO GÁS NATURAL E BIOCOMBUSTÍVEIS, *Anuário Estatístico Brasileiro de Petróleo, Gás Natural e Bicomcombustíveis*, ANP, Rio de Janeiro, 2010.

AITOKHUENI , I., DURLOSFSKY, L. J., *Optimizing the Performance of Smart Wells in Complex Reservoirs Using Continuously Updated Geological Models*, Journal of Petroleum Science and Engineering, 48, 254-264, 2005.

ANEEL - AGÊNCIA NACIONAL DE ENEGIA ELÉTRICA - BRASIL, *Atlas de energia elétrica do Brasil*, Brasília, 2008.

ARONOFSKY, J. S., LEE, A. S., *A Linear Programming Model for Scheduling Crude Oil Production*, SPE 862, Journal of Petroleum Technology, 10; pp 51-54;1958.

ARORA, J. S. *Introduction to Optimum Design*. McGraw Hill, 1989.

ASHEIM, H., *Maximization of Water Sweep Efficiency by Controlling Production and Injection Rates*, paper number SPE paper 18365 presented at the SPE European Petroleum Conference, London, UK, 1988.

ATTRA, H. D., WISE, H. B., BLACK, W. M. *Application of Optimizing Techniques for Studying Field Producing Operations*, J. Petro. Tech. 82-86, 1961.

AZIZ, S. O., *Comparison of Solutions to a Three-Dimensional Black-Oil Reservoir Simulation Problem*, Journal of Petroleum Technology, 1981.

BROUWER, D.R., *Dynamic Water Flood Optimization with Smart Wells using Optimal Control Theory*, PhD Thesis, Delft University of Technology, Delft, Netherlands, 2004.

BROUWER, D.R., JASEN, J.D., *Dynamic Optimization of Water Flooding with Smart Wells using Optimal Control Theory*, SPE paper 78278 presented at the SPE European Petroleum Conference, Aberdeen, UK, 2002.

BRIAND, L., FREIMUT, B., VOLLEI, F. *Using Multiple Adaptive Regression Splines to Understand Trends in Inspection Data and Identify Optimal Inspection Rates*. International Software Engineering Research Network, Technical report, ISERN TR 00-07, 2000.

CAERS, J., *The Probability Perturbation Method: An Alternative to Traditional Bayesian Approaches for Solving Inverse Problems*, presented at the 9th European Conference on the Mathematics of Oil Recovery, Cannes, France, 2004.

CARMO, A. *Técnicas de Otimização por Aproximação Sequencial Aplicadas a Ajuste de Histórico na Simulação de Reservatório*, Dissertação de Mestrado, Departamento de Engenharia Mecânica, UFPE, Brasil, 2010.

CARROLL, J. A., *Multivariate Production Systems Optimization*, Master of Science Thesis, Department of Petroleum Engineering, Stanford University, 1990.

CHAVENT, C., DUPUY, M., LEMONNIER, P. *History Matching by Use of Optimal Control Theory*, paper SPE 4627, presented at the SPE-AIME 48th Annual Fall Meeting, Las Vegas, Nevada, 1973.

CHAVENT, G., COHEN, G. *Determination of Relative Permeabilities and Capillary Pressures by an Automatic Adjustment Method*, paper SPE 9237, presented at the 55th Annual Fall Technical Conference and Exhibition, Dallas, Texas, 1980.

CHEN, W.H.; GAVALAS, G.R.; SEINFELD, J.H.; WASSERMAN, M.L.: *A New Algorithm for Automatic History Matching*. SPEJ 4545, 1974.

CHONG, E. K., ZAK, S. H. *An introduction to Optimization*. John Willey & Sons, New York, 2001.

CMG - COMPUTER MODELING GROUP Ltd. *IMEX, User's Guide*, 2006.

COSTA, A. P., *Quantificação do Impacto de Incertezas e Análise de Risco no Desenvolvimento de Campos de Petróleo*, Tese de Doutorado, Engenharia de Petróleo, UNICAMP, Brasil, 2006.

CRUZ, P. S., *Reservoir Management Decision Making in The Presence of Geological Uncertainty*, Stanford University, PHD thesis, 2000

CULLICK, A.S.; HEATH, D.; NARAYANAN, K.; APRIL, J.; KELLY, J.; *Optimizing Multiple-Field Scheduling and Production Strategy with Reduced Risk*; SPE 84239, Annual Technical Conference and Exhibition in Denver, Colorado; 2003.

DEUTSCH, V. C., JOURNAL, A. G. GSLIB: *Geostatistical Software Library and User's Guide*, Applied Geostatistics Series, Oxford Press, 1997.

DU, Q., VANCE F., GUNZBURGER; M. *Centroidal Voronoi Tessellations: Applications and Algorithms*, Society for Industrial and Applied Mathematics, 1999.

ELDRED, M.S, GIUNTA, A. A., WOJTKIEWICZ, J., TRUCANO, T. G. *Formulations for Surrogate-Based Optimization Under Uncertainty*. AIAA Paper 2002-5585, 2002.

ELDRED, M. S., DUNLAVY, D. M., *Formulations for Surrogate-Based Optimization with Data Fit, Multifidelity, and Reduced-Order Models*. 11th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, Portsmouth, Virginia, 2006.

ELDRED, M. S., WEBSTER, C. G. *Evaluation of non-Intrusive Approaches for Winer-Askey Generalized Polynomial Chaos*. AIAA Paper 2008-1892, 2008.

ELDRED, M. S. BURKARDT, J. *Comparison of Non-Intrusive Polynomial Chaos and Stochastic Collocation Methods for Uncertainty Quantification*. American Institute of Aeronautics and Astronautics, Paper 0976, 2009.

ELDRED, M. S. *Dakota* – <http://www.cs.sandia.gov/DAKOTA>, 2010.

FAITHI, Z., RAMIREZ, W.F., *Optimization of an Enhanced Oil Recovery Process with Boundary Controls - a Large Scale Nonlinear Maximization*, presented at the 4th IFAC Symposium on Control of Distributed Parameter Systems, Los Angeles, CA, 1985.

FASANINO, G., MOLINARD, J. E., MARSILY, G., PELCÉ, V. *Inverse Modeling in Gas Reservoirs*, paper SPE 15592, presented at the 61st SPE Annual Technical Conference and Exhibition, New Orleans, Texas, 1986.

FLORIS, F.J.T., PEERSMANN, M.R.H.E.: *E&P Decision Support System for Asset Management - A Case Study*, SPE 65146, SPE European Petroleum Conference, Paris, 2000.

FORRESTER, I. J., SÓBESTER, A., KEANE, A. J. *Engineering Design via Surrogate Modeling*, John Wiley and Sons, 2008.

FRIEDMAN, J. *Multivariate Adaptive Regression Splines*. The Annals of Statistics, Vol. 19, No. 1. , pp. 1-67, 1991.

GANO, S. E., RENAUD, J. E., 2004. *Variable Fidelity Optimization Using a Kriging Based Scaling Function*. Paper AIAA-2004-4460 in proceedings of 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, Albany-NY, 2004.

GEOQUEST Ltd, *Eclipse Technical Description*, Manual de Referência, 2005.

GILL, P. E., MURRAY, W., WRIGHT, M. H., *Practical Optimization*, Academic Press, New York, NY, 1982.

GIUNTA, A.A., WATSON, L.T. *A Comparison of Approximation Modeling Techniques: Polynomial Versus Interpolating Models*. Paper AIAA-98-4758 in proceedings of 7th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis & Optimization, St. Louis, MI, 1998.

GIUNTA, A. A., ELDRED, M. S. *Implementation of a Trust Region Model Management Strategy in The Dakota Optimization Toolkit*, 2000.

GIUNTA, A. A., *Use of Data Sampling, Surrogate Models, and Numerical Optimization in Engineering Design*, Proceedings of the 40th AIAA Aerospace Sciences Meeting and Exhibit, Reno, NV, 2002.

GIUNTA, A.A., WOJTKIEWICZ, S.F., ELDRED, M.S., *Overview of Modern Design of Experiments Methods for Computational Simulations*, Proceedings of the 41st AIAA Aerospace Sciences Meeting and Exhibit, Reno, NV, 2003.

GHANEM, R.G., SPANOS, P. *Stochastic Finite Elements: A Spectral Approach*, Springer, Berlin, 1991.

GHANEM, R. *Probabilistic Characterization of Transport in Heterogeneous Media. Computer Methods in Applied Mechanics and Engineering*, Elsevier, 158 199-220, 1998.

GLOVER, F., MARTÍ, R., *Fundamentals of Scatter Search and Path Relinking*, Control and Cybernetics, Vol. 29, No. 3, pp. 653-684, 2000.

GNU OCTAVE - <http://www.gnu.org/software/octave>, 2010.

GOLDBERG, D. E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, Reading, MA, 1989.

GOLUB, G., LOAN, V. *Matrix Computation*. The John Hopkins Press, Baltimore, 1996.

GRAYSON, C. J. *Decisions Under Uncertainty - Drilling Decisions by Oil and Gas Operators*. Harvard University, Division of Research, Graduate School of Business Administration, Boston, 1960.

GURNEY, K. *An Introduction to Neural Networks*, Taylor and Francis Group, Londres, 1997.

HALTON, J. H. *A Retrospective and Prospective Survey of the Monte Carlo Method*. SIAM, 1970.

HANS, O. J. *A Rapid Method for Obtaining a Two-Dimensional Reservoir Description From Well Pressure Response Data*, SPE 1473, 1966.

HASTIE, T., TIBSHIRANI, R., FRIDMAN, J. *The Elements of Statistical Learning, Data Mining, Inference, and Prediction*. Springer-Verlag, 2001.

HARTING, T.J., RADCLIFF, N.J., KING, P.R. *Hydrocarbon Production Schedule with Genetic Algorithms*; SPE 36379, SPE Journal, 6; 1998.

HAYWARD, J. T., *Probabilities and wildcats*. In Drill. and Prod. Prac., 1934.

HILLS, R.G., TRUCANO, T.G. *Statistical validation of engineering and scientific models: background*, Technical Report SAND99- 1256, Sandia National Laboratories, 1999.

HUANG, S. P., QUEK, S. T., PHOON, K. K. *Convergence study of the truncated Karhunen–Loeve expansion for simulation of stochastic processes*. International Journal for Numerical Methods in Engineering. 52:1029–1043, 2001.

HUPPLER, J.D.; *Scheduling Gas Field Production for Maximum Profit*; SPE Journal, 16: 274-279; 1974.

IEA - INTERNATIONAL ENERGY AGENCY, *World Energy Outlook*, 2010.

IEA - INTERNATIONAL ENERGY AGENCY , *Key World Energy Statistics*, Paris, 2010.

JACQUARD, P. *Théorie de Interprétation des Mesures de Pression*. Revue IFP, March, 1964.

JACQUARD, P.; JAIN, C. *Permeability Distribution From Field Pressure Data*. SPE 1307, 1965.

JONES, D. R., SCHONLAU, M., WELCH, W. J. *Efficient Global Optimization of Expensive Black-Box Functions*. Kluwer Academic Publishers, 1998.

KEANE, A.J., NAIR, P.B., *Computational Approaches for Aerospace Design: The Pursuit of Excellence*, John-Wiley and Sons, 2005.

KENNEDY, M. C., HANGAN, A., *Predicting the output from a complex computer code when fast approximation is available*. Biometrika, 87, PP 1-13., 2000.

KIRPARTRIC, S., GELATT JR, C. D., VECCHI, M. P., *Optimization by simulated annealing*. Science 220 (4598), 671– 680, 1983.

KOCIS, L, WHITEN, J. W., *Computational Investigations of Low-discrepancy Sequences*, ACM Transactions on Mathematical Software, 1997.

KULLER , R. G., CUMMINGS, R. G.: *An Economic Model for Investment and Production for Petroleum Reservoirs*, Am. Econ. Rev. **64** 66-79, 1974.

KWORK, J. T., TSANG, I. W. *The pre-image problems with kernel methods*. International Conference on Machine Learning, 2003.

LEITÃO, H. C. *Ajuste de Histórico Automatizado, através de Otimização Multivariada e Paralelização Externa*, Dissertação de Mestrado, Campinas, 1997.

LI, R., REYNOLDS, A. C., OLIVER, D. S. *History Matching of Three-Phase Flow Production Data*, paper SPE 66351, presented at the Reservoir Simulation Symposium, Houston, Texas, 2001.

LOPHAVEN, S.N., NILSEN, H.B., SONDERGAARD, J. *DACE - A MATLAB Kriging Toolbox*. Technical Report IMM-TR-2002-12, Technical University of Denmark, Lyngby, Version 2.0, 2002.

MADSEN, R. E., HANSEN, L. K., WINTHER, O. *Singular Value Decomposition and Principal Component Analysis*, 2004.

MASCHIO, C., SCHIOZER, D. J. *Aplicação de metodologia para a automatização de ajuste histórico*. 2º Congresso Brasileiro de P&D em Petróleo & Gás. Rio de Janeiro, 2003.

MATHWORKS. *Statistics Toolbox User's Guide*, 2001.

MCFARLAND, J. W., LASDSON, L., and LOOSE, V.: *Development Planning and Management of Petroleum Reservoirs Using Tank Models and Nonlinear Programming*, Operations Research n. 32, 270-289, 1984.

MEYER, P. L. *Probabilidade: Aplicações à Estatística*, LTC, 2000.

MME - MINISTÉRIO DE MINAS E ENERGIA, GOVERNO FEDERAL - BRASIL, *Contexto mundial e preço do petróleo: uma visão de longo prazo*, EPE, 2008.

MOURA FILHO, M. *Integração de Análise de Incertezas e Ajuste de Histórico de Produção*, Dissertação de Mestrado, Campinas, 2006.

NEWENDORP, D. *Decision Analysis for Petroleum Exploration*. The Petroleum Publishing Company, Tulsa, 1975.

NNEDY, M. C., O'HAGAN, A. *Predicting the output from a complex computer code when fast approximation is available*. Biometrika, 2000.

NOCENDAL, J., WRIGHT, S. J., *Numerical Optimization*, Springer Series in Operations Research, Springer-Verlag, New York, 1999.

OLIVEIRA, D. F. B., *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, Engenharia Civil, UFPE, Brasil, 2006.

OLIVER, D. S., REYNOLDS, A. C, LIU, N. *Inverse Theory for Petroleum Reservoir Characterization and History Matching*, Cambridge University Press, 2008.

PAN, Y.; HORNE, N.R.; *Improved Methods for Multivariate Optimization of Field Development Scheduling and Well Placement Design*; SPE 49055, Annual Technical Conference and Exhibition in New Orleans, Louisiana; 1998.

QUEIPO, N. V., HAFTKA, R. T., SHYY, W., GOEL, T., VAIDYANATHAN, R., TUCKER, P. K. *Surrogate-Based Analysis and Optimization*, Progress in Aerospace Sciences, 2005.

RAO, S. S, *Engineering Optimization: Theory e Practice*, Wiley, New Jersey, 2009.

ROSA, A. J. CARVALHO, R. S., XAVIER, J. A. D. *Engenharia de Reservatórios de Petróleo*, Interciência, 2006.

ROWAN, G., WARREN, J. E., *A system approach to reservoir engineering*, Optimum Development Planning. J. Can. Pet. Technology. 84-94; 1967.

SARMA, P., DURLOFSKY, L. J., AZIZ, K., *Efficient Closed-Loop Production Optimization Under Uncertainty*, SPE 94241, 2004.

SARMA, P. *Efficient Closed-Loop Optimal Control of Petroleum Reservoir Under Uncertainty*. Phd Thesis, Stanford University, Stanford, CA, 2006.

SARMA, P., DURLOFSKY, L. J., AZIZ, K. *A New Approach to Automatic History Matching Using Kernel PCA*. SPE Reservoir Simulation Symposium, Houston, Texas, U.S.A, 2007.

SARMA, P., DURLOFSKY, L. J., AZIZ, K. *Kernel Principal Component Analysis for Efficient Differentiable Parameterization of Multipoint Geostatistics*. Math Geosci 40:3-32, 2008.

SATTER, A., THAKUR, G. C. *Integrated Petroleum Reservoir Management, A Team Approach*, Pennwell Books, 1994.

SCHOLKOPF, B., SMOLA, A, MULLER, K., *Nonlinear Component Analysis as a Kernel Eigenvalue Problem*, Technical Report No. 44, Max-Planck Institut für biologische Kybernetik, Arbeitsgruppe Bülhoff, 1996.

SCHOLKOPF, B., MIKA, S., SMOLA, A, RATSCH, G., MULLER, K., *Kernel PCA pattern reconstruction via approximate pre-images*, 8 th international conference on artificial neural networks, Shvde, Suécia, 1998.

SEE, B.A.; HORNE, R.N.; *Optimal Reservoir Production Scheduling by Using Reservoir Simulation*; SPE 11133, Annual Technical Conference and Exhibition in New Orleans, Louisiana; 1983.

SIMPSON, T. W., BOOKER, A. J., GOSH, D., GIUNTA, A. A., KOCH, P. N., YANG, R. J., *Approximation Methods in Multidisciplinary Analysis and Optimization: A Panel Discussion*, Structural and Multidisciplinary Optimization, Vol. 27, No. 5, pp. 302-313, 2004.

SMITH, B. *Probability models for petroleum investment decisions*. Journal of Petroleum Technology, pages 543-550, 1970.

SUDARYANTO, B., YORTSOS, Y.C., *Optimization of Displacements in Porous Media Using Rate Control*, SPE paper 71509 presented at the SPE Annual Technical Conference and Exhibition, New Orleans, LA, 2001.

TARANTOLA, A. *Inverse Problem Theory and Methods for Model Parameters Estimation*, Siam, 2005.

TATANG, M. *Direct Incorporation of Uncertainty in Chemical and Environmental Engineering Systems*. Phd Thesis, MIT, 1995.

THOMAS, J. E. *Fundamentos de Engenharia de Petróleo*, Interciência, 2001.

URROZ, G., *Uncertainty in Engineering Analysis – An Introduction*, lecture notes, 2005.

VAN BEERS, W. C. M., KLEIJNEN, J. P. C. *Kriging Interpolation in Simulation: a Survey*, Proceedings of the 2004 Winter Simulation Conference, 2004.

VAN ESSEN, G.M., ZANDVLIET, M. J., VAN DEN HOF, P. M. J., BOSGRA, O. H. *Robust Waterflooding Optimization of Multiple Geological Scenarios*, SPE 102913, SPE Journal, 2006.

VIRONOVSKY, G.A., *Waterflooding Strategy Design Using Optimal Control Theory*, presented at the 6th European IOR Symposium, Stavanger, Norway, 1991.

XIU, D., KARNIADAKIS, G. *Modeling Uncertainty in Flow Simulation via Generalized Polynomial Chaos*. Journal of Computational Physics 187 137-167, 2003.

WASSERMAN, M. L., EMANUEL, A. S., SEINFELD, J. H. *Practical Applications of Optimal Control Theory to History-Matching Multiphase Simulator Models*, paper SPE 5020, presented at the SPE-AIME 49th Annual Fall Meeting, Houston, Texas, 1974.

WATTENBARGER, R. A.: *Maximizing Seasonal Withdrawals from Gas Storage Reservoirs*, J. Petro. Tech. 994-998, 1970.

YANG, P. H.; ARMASU, R.V AND WATSON, A.T.: *Automatic History Matching with Variable Metric Methods*, SPE 16977, 1987.

ZAKIROV, I.S., AANONSEN, S.I., ZAKIROV, I.S., PALATNIK, B.M., *Optimization of Reservoir Performance by Automatic Allocation of Well Rates*, presented at the 5th European Conference on the Mathematics of Oil Recovery, Leoben, Austria, 1996.