



Alexandre de Castro Almeida

**Aproximador de Função para Simulador
de Reservatórios Petrolíferos
Utilizando Técnicas de Inteligência Computacional e
Projeto de Experimentos Fatoriais Fracionado**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para
obtenção do grau de Mestre pelo Programa de Pós-
Graduação em Engenharia Elétrica da PUC-Rio.

Orientadora: Marley Maria Bernardes Rebuszi Vellasco

Rio de Janeiro
Setembro de 2008



Alexandre de Castro Almeida

Aproximador de Função para Simulador de Reservatórios Petrolíferos Utilizando Técnicas de Inteligência Computacional e Projeto de Experimentos Fatoriais Fracionado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC -Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Profa. Marley Maria Bernardes Rebuszi Vellasco
Orientadora

Departamento de Engenharia Elétrica - PUC-Rio

Prof. Leandro Costa Reis
Petrobras

Prof. Denis José Schiozer
UNICAMP

Prof. Juan Guillermo Lazo Lazo
Departamento de Engenharia Elétrica - PUC-Rio

Prof. José Eugenio Leal
Coordenador Setorial do Centro Técnico Científico

Rio de Janeiro, 12 de Setembro de 2008

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

Alexandre de Castro Almeida

Graduou-se em Engenharia Elétrica na Universidade do Estado do Rio de Janeiro (UERJ).

Ficha Catalográfica

Almeida, Alexandre de Castro

Aproximador de função para simulador de reservatórios petrolíferos: utilizando técnicas de inteligência computacional e projeto de experimentos fatoriais fracionado / Alexandre de Castro Almeida; orientador: Marley Maria Bernardes Rebuszi Vellasco. – 2008.

119 f. : il.(color.) ; 30 cm

Dissertação (Mestrado em Engenharia Elétrica)– Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

Inclui bibliografia

1. Engenharia Elétrica – Teses. 2. Aproximador de função. 3. Projeto de experimentos. 4. Inteligência computacional. 5. Engenharia de reservatórios. 6. Campos de petróleo inteligentes. 7. Otimização. I. Vellasco, Marley Maria Bernardes Rebuszi. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título

CDD: 621.3

Aos meus pais Lilia (*in memoriam*) e João,
À minha esposa Luciana e ao meu filho Giovanni.

Agradecimentos

À minha amada esposa e fonte de motivação Luciana Faletti Almeida, que sem seu apoio e orientação nada disso seria possível.

Aos meus queridos pais João de Almeida e Lilia de Castro Almeida por todo amor, oportunidades proporcionadas, ensinamentos e apoio.

Ao meu filho Giovanni Faletti Almeida pelo seu sorriso.

Às minhas queridas irmãs Érica e Patrícia.

À minha orientadora Marley Maria Bernardes Rebuzzi Vellasco pela confiança e apoio em momentos-chave.

Aos amigos da PUC-Rio, pelo apoio e importantes contribuições.

Aos amigos que, de uma forma ou de outra, contribuíram para o final feliz.

Resumo

Almeida, Alexandre de Castro; Vellasco, Marley Maria Bernardes Rebuzzi. **Aproximador de Função para Simulador de Reservatórios Petrolíferos Utilizando Técnicas de Inteligência Computacional e Projeto de Experimentos Fatoriais Fracionado**. Rio de Janeiro, 2008. 119p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Em diversas etapas da cadeia de trabalho da Indústria de Óleo & Gás a atividade de Engenharia de Petróleo demanda processos que envolvem otimização. Mais especificamente, no gerenciamento de reservatórios, as metodologias para a tomada de decisão pelo uso de poços inteligentes envolvem processos de otimização. Nestes processos, normalmente, visa-se maximizar o VPL (Valor Presente Líquido), que é calculado através das curvas de produção de óleo, gás e água fornecidas por um simulador de reservatório. Estas simulações demandam alto custo computacional, muitas vezes inviabilizando processos de otimização. Neste trabalho, empregam-se técnicas de inteligência computacional – modelos de redes neurais artificiais e neuro-fuzzy – para a construção de aproximadores de função para simulador de reservatórios com o objetivo de diminuir o custo computacional de um sistema de apoio à decisão para utilização ou não de poços inteligentes em reservatórios petrolíferos. Para reduzir o número de amostras necessárias para a construção dos modelos, utiliza-se também Projeto de Experimentos Fatoriais Fracionado. Os aproximadores de função foram testados em dois reservatórios petrolíferos: um reservatório sintético, muito sensível às mudanças no controle de poços inteligentes e outro com características reais. Os resultados encontrados indicam que estes aproximadores de reservatório conseguem bom desempenho na substituição do simulador no processo de otimização – devido aos baixos erros encontrados e à substancial diminuição do custo computacional. Além disto, os testes demonstraram que a substituição total do simulador pelo aproximador se revelou uma interessante estratégia para utilização do sistema de otimização, fornecendo ao especialista uma rápida ferramenta de apoio à decisão.

Palavras-chave

Aproximador de Função; Projeto de Experimentos; Inteligência Computacional; Engenharia de Reservatórios; Campos de Petróleo Inteligentes; Otimização.

Abstract

Almeida, Alexandre de Castro; Vellasco, Marley Maria Bernardes Rebuszi. **Black Oil Reservoirs Simulator Proxy Using Computational Intelligence and Fractional Factorial Design of Experiments.** Rio de Janeiro, 2008. 119p. MSc. Dissertation – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

In many stages of the work chain of Oil & Gas Industry, activities of petroleum engineering demand processes that involve optimization. More specifically, in the reservoirs' management, the methodologies for decision making by using intelligent wells involve optimization processes. In those processes, usually, the goal is to maximize the NVP (Net Present Value), which is calculated through the curves of oil, gas and water production, supplied by a reservoir simulator. Such simulations require high computational costs, therefore in many cases the optimization processes become unfeasible. Techniques of computational intelligence are applied in this study – artificial neural networks and neuro-fuzzy models – for building proxies for reservoirs simulators aiming at to reduce the computational cost in a decision support system for using, or not, intelligent wells within oil reservoirs. In order to reduce the number of samples needed for build the models, it was used the Fractional Factorial Design of Experiments. The proxies have been tested in two oil reservoirs: a synthetic one, very sensitive to changes in the control of intelligent wells and another one with real characteristics. The replacement of the simulator by the reservoir proxy, in an optimization process, indicates a good result in terms of performance – low errors and significantly reduced computational costs. Moreover, tests demonstrate that the total replacement of the simulator by the proxy, turned out to be an interesting strategy for using the optimization system, which provides to the users a very fast tool for decision support.

Keywords

Proxy; Design of Experiments; Computational Intelligence; Reservoir Engineering; Intelligent Fields; Optimization.

Sumário

1	Introdução	14
1.1.	Motivação	14
1.2.	Objetivos	15
1.3.	Descrição da dissertação	16
1.4.	Organização da dissertação	17
2	Fundamentação Teórica	19
2.1.	Introdução	19
2.2.	Projeto de Experimentos	19
2.2.1.	Introdução	19
2.2.2.	Projeto de Experimentos Fatoriais Completo	22
2.2.3.	Projeto de Experimentos Fatoriais Fracionado	23
2.3.	Redes Neurais Artificiais	27
2.3.1.	Arquitetura Multilayer Perceptron	27
2.3.2.	Algoritmos de Aprendizado <i>Backpropagation</i>	28
2.4.	Modelos Neuro- <i>Fuzzy</i>	32
2.4.1.	Sistemas de Inferência <i>Fuzzy</i>	32
2.4.2.	Sistemas Neuro- <i>Fuzzy</i>	34
2.4.3.	ANFIS	34
3	Aproximador de Função para Simulador de Reservatório Petrolífero	37
3.1.	Introdução	37
3.2.	Otimização de Estratégia de Controle de Válvulas de Poços Inteligentes	38
3.3.	Etapas para a construção do aproximador	42
3.4.	Aquisição e Pré-processamento dos Dados de Treinamento	44
3.4.1.	Aquisição de Dados de Treinamento	45
3.4.2.	Seleção de Variáveis de Treinamento	45
3.4.3.	Limpeza dos Dados de Treinamento	47
3.4.4.	Transformação dos Dados de Treinamento	47
3.5.	Arquitetura do Aproximador de Simulador de Reservatório	47
3.5.1.	Determinação do Modelo para Construção do Aproximador	48

3.6. Aquisição dos Dados de Treinamento Utilizando Projeto de Experimentos Fatoriais Fracionado	49
3.6.1. Determinação da Quantidade de Simulações Necessárias para Treinamento	51
3.7. Política de Substituição do Simulador	52
4 Estudo de Casos	54
4.1. Parâmetros dos Modelos	55
4.2. Métricas de Avaliação	57
4.3. Definição dos Reservatórios e Configuração de Válvulas	57
4.3.1. Reservatório Sintético	57
4.3.2. Reservatório Real	59
4.4. Avaliação do Desempenho dos Aproximadores	61
4.4.1. Teste 1	62
4.4.2. Teste 2	63
4.4.3. Teste 3	64
4.4.4. Teste 4	65
4.4.5. Teste 5	66
4.4.6. Teste 6	68
4.5. Avaliação do Aproximador no Sistema de Otimização de Estratégia de Controle de Válvulas de Poços Inteligentes	73
4.5.1. Avaliação da Política de Substituição do Simulador	74
4.5.2. Teste de Otimização no Sistema de Otimização de Estratégia de Controle de Válvulas de Poços Inteligentes	77
4.6. Análise do Custo Computacional	78
5 Conclusões e Trabalhos Futuros	82
5.1. Conclusões	82
5.2. Trabalhos Futuros	83
Referências Bibliográficas	84
Apêndice A – Projeto de Experimentos Fatoriais Fracionados	88
Apêndice B – Simulador de Reservatórios IMEX	106

Lista de figuras

Figura 1 – Estrutura de um experimento.	20
Figura 2 – Visualização gráfica do efeito principal dos fatores A e B.	21
Figura 3 – Visualização gráfica do efeito de interação dos fatores A e B.	22
Figura 4 – Visão geométrica de projeto de experimentos fatoriais com três fatores com dois níveis cada.	25
Figura 5 - Representação geral da arquitetura <i>multilayer perceptron</i> (<i>feedforward</i>).	28
Figura 6 – Identificação do ponto de interrupção do treinamento com o método da parada antecipada.	31
Figura 7 – Arquitetura do ANFIS (Jang,1993).	35
Figura 8 – Principais módulos do sistema otimizador.	39
Figura 9 – Entradas fornecidas pelo processo de otimização de válvulas para o simulador (exemplo para válvulas on/off).	40
Figura 10 – Entradas fornecidas pelo processo de otimização de válvulas para o simulador (exemplo para válvulas de abertura contínua).	40
Figura 11 – Sistema de otimização com a utilização do aproximador.	43
Figura 12 – Entradas e saídas do aproximador.	43
Figura 13 – Etapas para a construção do aproximador.	44
Figura 14 – LSE. (a) óleo; (b) gás; (c) água.	46
Figura 15 – Detalhe da modelagem do aproximador. (a) Predição da curva de água sem óleo. (b) Predição da curva de água com óleo.	48
Figura 16 – Fluxograma do mecanismo da decisão de utilização do simulador ou aproximador.	53
Figura 17 – Alternativa utilizada nos testes do reservatório sintético. O poço inteligente está indicado em vermelho.	58
Figura 18 – Campo real com 9 válvulas. Poços inteligentes estão indicados em vermelho.	60
Figura 19 – Campo real com 6 válvulas. Poços inteligentes estão indicados em vermelho.	61
Figura 20 – Curva de óleo obtida pelo simulador (azul) e pelo aproximador (vermelha).	67
Figura 21 – Curva de gás obtida pelo simulador (azul) e pelo aproximador (vermelha).	68

Figura 22 – Curva de água obtida pelo simulador (azul) e pelo aproximador (vermelha).	68
Figura 23 – Curvas Real e Prevista de produção diária de óleo (10 amostras). Modelo RNA (5) da Tabela 17.	70
Figura 24 – Curvas Real e Prevista de produção diária de gás (10 amostras). Modelo RNA (5) da Tabela 17.	70
Figura 25 – Curvas Real e Prevista de produção diária de água (10 amostras). Modelo RNA (5) da Tabela 17.	71
Figura 26 – Curva de óleo obtida pelo simulador (azul) e pelo aproximador (vermelha). Modelo RNA (5) da Tabela 17.	71
Figura 27 – Curva de gás obtida pelo simulador (azul) e pelo aproximador (vermelha). Modelo RNA (5) da Tabela 17.	71
Figura 28 – Curva de água obtida pelo simulador (azul) e pelo aproximador (vermelha). Modelo RNA (5) da Tabela 17.	72
Figura 29 – Curva de água obtida pelo simulador (azul) e pelo aproximador (vermelha). Modelo RNA (5) da Tabela 17.	72
Figura 30 – Curvas de evolução do sistema de otimização. (a) 0% de substituição do simulador; (b) 25% de substituição do simulador; (c) 50% de substituição do simulador; (d) 75% de substituição do simulador; (e) 100% de substituição do simulador.	76
Figura 31 – Curvas de evolução do sistema de otimização com 100% de substituição do simulador.	78
Figura 32 – Relação entre tempo de processamento e percentual de substituição do simulador, de acordo com a política de substituição proposta.	78
Figura 33 – Arquivos de entrada e saída do IMEX.	108

Lista de tabelas

Tabela 1 – Projeto de experimentos fatoriais completo com dois fatores com dois níveis cada e sua interação.	23
Tabela 2 – Projeto de experimentos fatoriais fracionado com 3 fatores e 2 níveis cada. O fator <i>C</i> se confunde com o efeito de interação dos fatores <i>A</i> e <i>B</i> .	24
Tabela 3 – Projeto de experimentos fatoriais completo com 3 fatores e 2 níveis cada. Referência à Figura 4.	26
Tabela 4 – Projeto de experimento fatoriais fracionado à metade com 3 fatores e 2 níveis cada referente à Figura 4.	26
Tabela 5 – Níveis de abertura das válvulas para o projeto de experimentos.	50
Tabela 6 – Quantidade de simulações necessárias para treinamento dos cenários utilizando projeto de experimentos fatoriais completo e fracionado.	52
Tabela 7 – Cenários de substituição do simulador no processo de otimização.	53
Tabela 8 – Parâmetros das Redes Neurais Artificiais.	56
Tabela 9 – Estrutura de apresentação dos resultados para os aproximadores.	61
Tabela 10 – Configuração do microcomputador utilizado para construção do aproximador.	62
Tabela 11 – Erros de teste para o aproximador com dados de treinamento obtidos de forma aleatória (Teste 1 com 320 amostras).	63
Tabela 12 – Erros de teste para o aproximador com dados de treinamento obtidos de forma aleatória (Teste 1 com 64 amostras).	63
Tabela 13 – Erros de teste para o aproximador com dados de treinamento obtidos através de projeto de experimentos (Teste 2).	64
Tabela 14 – Erros de teste para o aproximador com dados de treinamento obtidos de forma aleatória (Teste 3).	65
Tabela 15 – Erros de teste para o aproximador com dados de treinamento obtidos através de projeto de experimentos (Teste 4).	66
Tabela 16 – Erros de teste para o aproximador com dados de treinamento obtidos de forma aleatória (Teste 5).	67
Tabela 17 – Erros de teste para o aproximador com dados de treinamento	

obtidos através de projeto de experimentos (Teste 6).	69
Tabela 18 - Configuração do microcomputador utilizado no sistema de otimização.	73
Tabela 19 – Parâmetros do algoritmo genético do sistema de otimização.	74
Tabela 20 – Resultado do sistema de otimização para a política de substituição do simulador.	75
Tabela 21 – Parâmetros do algoritmo genético do sistema de otimização.	77
Tabela 22 – Custo computacional total para aquisição das amostras para construção dos aproximadores.	79
Tabela 23 – Parâmetros do algoritmo genético - Tabela 16 de Faletti (2007).	80
Tabela 24 – Análise da economia da utilização do aproximador no sistema de otimização de (Faletti, 2007) para 11.250 avaliações para o Campo Real.	80