



Yván Jesús Túpac Valdivia

**Sistema Inteligente de Otimização de Alternativas de
Desenvolvimento de Campos Petrolíferos**

Tese de Doutorado

Tese apresentada como requisito parcial para obtenção
do título de Doutor pelo programa de Pós-Graduação em
Engenharia Elétrica da PUC-Rio.

Orientadores: Marley Maria Bernardes Rebuzzi Vellasco
Marco Aurélio Cavalcanti Pacheco

Rio de Janeiro, março de 2005



Yván Jesús Túpac Valdivia

Sistema Inteligente de Otimização de Alternativas de Desenvolvimento de Campos Petrolíferos

Tese apresentada como requisito parcial para obtenção do grau de Doutor 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.

Dra. Marley Maria Bernardes Rebuzzi Vellasco
Orientadora
Departamento de Engenharia Eletrica – PUC-Rio

Dr. Marco Aurélio Cavalcanti Pacheco
Orientador
Departamento de Engenharia Elétrica – PUC-Rio

Dr. Régis Kruel Romeu
PETROBRÁS

Dr. Denis José Schiozer
UNICAMP

Dr. Antônio Carlos Bittencourt de Andrade Filho
PETROBRÁS

Dr. Ricardo Cunha Mattos Portella
PETROBRÁS

Dr. Sérgio Augusto Barreto da Fontoura
Departamento de Engenharia Civil – PUC-Rio

Dra. Karla Tereza Figueiredo Leite
UERJ

Dr. Carlos Roberto Hall Barbosa
Departamento de Engenharia Elétrica – PUC-Rio

Prof. José Eugenio Leal
Coordenador Setorial do Centro
Técnico Científico – PUC-Rio

Rio de Janeiro, 28 de março de 2005

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

Yván Jesús Túpac Valdivia

Graduou-se em Engenharia Eletrônica na Universidad Nacional de San Agustín de Arequipa (Peru) em 1995. Obteve o título de Mestre em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro em 2000, tendo como área de concentração: Métodos de apoio à Decisão e como linha de pesquisa: Inteligência Computacional Aplicada. Desenvolveu junto aos seus orientadores diversos projetos voltados para a indústria.

Ficha Catalográfica

Túpac Valdivia, Yván Jesús

Sistema inteligente de otimização de alternativas de desenvolvimento de campos petrolíferos / Yván Jesús Túpac Valdivia; orientadores: Marley Maria Bernardes Rebuza Vellasco, Marco Aurélio Cavalcanti Pacheco. – Rio de Janeiro : PUC-Rio, Departamento de Engenharia Elétrica, 2005.

163 f. ; 30 cm

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

Inclui bibliografia

1. Engenharia Elétrica – Teses. 2. Otimização. 3. Algoritmos evolucionários. 4. Engenharia de reservatórios. 5. Aproximação de funções. 6. Modelos neuro-Fuzzy. 7. Redes neurais. 8. Processamento distribuído I. Vellasco, Marley Maria Bernardes Rebuza. II. Pacheco, Marco Aurélio Cavalcanti. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

Para minha esposa *Maria* e meus filhos *Luis Fernando* e *Juan Gabriel*

Agradecimentos

Aos meus orientadores: professores Marley M. B. R. Vellasco e Marco Aurélio C. Pacheco pelo apoio e confiança depositados durante a realização deste trabalho.

À CAPES, CNPq, e PUC-Rio pelo auxílios financeiros e infra-estruturais concedidos.

Aos Doutores Ricardo Cunha Mattos Portella do CENPES e Marco Antônio Guimarães Dias da PETROBRAS pelas valiosas sugestões durante a realização deste trabalho.

À corporação *Computer Modelling Group* (CMG) pelo suporte concedido no pacote de simulação de reservatório IMEX.

Aos colegas do laboratório ICA e colegas dos projetos ANEPI I, II e III: Édison, Juan, Luciana, Karla pelo apoio e amizade oferecidos.

Aos professores, pesquisadores, pessoal de suporte, demais alunos e funcionários do Departamento de Engenharia Elétrica da PUC-Rio.

À minha esposa María e filhos Luis Fernando e Juan Gabriel pelo apoio incondicional

Resumo

Túpac Valdivia, Yván Jesús. **Sistema Inteligente de Otimização de Alternativas de Desenvolvimento de Campos Petrolíferos.** Rio de Janeiro, 2005. 163p. Tese de Doutorado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Este trabalho investiga o problema de otimização de alternativas para o desenvolvimento de campos petrolíferos. Uma alternativa de desenvolvimento refere-se à forma como um campo petrolífero, conhecido e delimitado, é colocado em produção, isto é, diz respeito à determinação do número, localização e agendamento dos poços de produção e injeção. Otimização de alternativas consiste em encontrar as configurações de produção que, a longo prazo, forneçam o maior valor presente líquido (VPL), obtido a partir do custo de investimento inicial, do preço do petróleo, da produção de óleo e gás, dos custos de operação, das alíquotas de impostos e dos *royalties* pagos durante o tempo de produção. A produção de óleo é obtida usando-se um simulador de reservatório. O simulador recebe a informação da alternativa a ser simulada e retorna a curva de produção de óleo e gás no tempo de produção especificado. Cada execução do simulador pode demorar desde alguns segundos até várias horas, dependendo da complexidade do reservatório modelado. Este trabalho propõe, implementa e avalia um sistema inteligente de otimização que emprega: algoritmos genéticos (AGs) para a busca de uma alternativa de desenvolvimento ótima; uso de ambiente de computação paralela para a simulação de reservatório e cálculo do VPL das alternativas; um módulo de inferência baseado em modelos inteligentes para aproximar a função de produção de óleo; e um módulo de caracterização baseado em mapas de qualidade para obter informações do campo petrolífero a serem aproveitadas durante a otimização. Este trabalho consistiu de 4 etapas: uma revisão da literatura sobre desenvolvimento de campos petrolíferos, simulação de reservatórios e caracterização de campos petrolíferos; um estudo das técnicas de inteligência computacional para otimização e aproximação de funções; desenvolvimento do modelo proposto de otimização de alternativas; e o estudo de casos. O modelo proposto foi avaliado com configurações de reservatório homogêneo e heterogêneo obtendo resultados da otimização, do uso da caracterização, da aproximação pelo módulo de inferência e do uso do ambiente

paralelo. Os resultados obtidos mostram que, o modelo proposto, permite alcançar respostas com altos VPL sem utilizar conhecimento prévio, e também a partir de informações extraídas da caracterização ou fornecidas pelo próprio especialista como sementes iniciais na otimização. A principal contribuição deste trabalho é a concepção e implementação de um sistema baseado em técnicas inteligentes para otimizar alternativas de desenvolvimento com uma redução do tempo computacional para um processo iterativo, obtida tanto pelo aproveitamento do poder computacional de um ambiente de computação paralela, como pelo uso de aproximações das curvas de produção. Este sistema inteligente oferece uma ferramenta de suporte à decisão que automatiza a busca de alternativas de desenvolvimento e aproveita informações vindas do conhecimento do engenheiro de reservatório.

Palavras-chave

Otimização, Algoritmos Evolucionários, Engenharia de Reservatórios, Aproximação de Funções, Modelos *Neuro-Fuzzy*, Redes Neurais, Processamento Distribuído.

Abstract

Túpac Valdivia, Yván Jesús. **Intelligent System for Optimization of Alternatives for Petroleum Fields Development.** Rio de Janeiro, 2005. 163p. PhD Thesis – Department of Electrical Engineering, Catholic University of Rio de Janeiro.

This work investigates the problem of optimization of alternatives for petroleum fields' development. A development alternative refers to the way a well-known and delimited petroleum field is placed in production. This process involves the determination of the number, localization and scheduling of producer and injector wells. Thus, the optimization of alternatives consists of finding the production configurations that, in the long term, provide the maximum net present value (NPV); this is obtained from the investment cost, oil price, oil & gas production, operation costs and taxes and royalties paid during the production time. The oil and gas production is obtained from a reservoir simulator. The simulator receives information from the alternative to be simulated, and returns an oil & gas production to specified production time. Each simulation can take from a few seconds to several hours, depending on complexity of the reservoir being modeled. This work proposes, implements and evaluates an intelligent optimization system that comprises: genetic algorithms (GAs) to search an optimal development alternative; using of parallel computing environment to reservoir simulation and NPV computing; an inference module, basis in intelligent models, to approximate the oil production function; and a oilfield characterization module, basis in quality maps, to obtain information about the oilfield to use during optimization process. This work consisted of four stages: a literature review about petroleum field development and reservoir simulation; a study about computational intelligence techniques applied in optimization and functions approximation; the development of alternatives optimization proposal model; and the case studies. The proposal model was evaluated using homogeneous and heterogeneous reservoir configurations, obtaining results of optimization, by using characterization, the inference module and the parallel environment. The obtained results indicate that the proposed model provides alternatives with high NPV without previous knowledge and also from information provided by characterization or information inserted by the expert as initial seeds into

optimization. The main contribution of this work is the conception and the implementation of a system basis in intelligent techniques to optimize development alternatives offering a reduction time to an iterative process, obtained from exploit of computational effort of a parallel computing environment or by using of production curves approximations. This intelligent system offers a decision-support tool that allows automating the search process of development alternatives and exploiting information from knowledge of reservoir engineers.

Keywords

Optimization, Evolutionary Algorithms, Reservoir Engineering, Function Approximation, Neuro-Fuzzy Models, Neural Networks, Distributed Processing.

Sumário

1 Introdução	18
1.1. Motivação	18
1.2. Objetivos	19
1.3. Descrição do Trabalho	20
1.4. Contribuições	21
1.5. Organização da Tese	22
2 Desenvolvimento de Campos Petrolíferos	24
2.1. Introdução	24
2.2. Fundamentos de Simulação de Reservatório	24
2.2.1. Simuladores de Reservatório	25
2.3. Engenharia Econômica	27
2.3.1. Analise de Alternativas de Investimento	28
2.3.2. Indicadores Econômicos	29
2.4. Mapas de Qualidade	31
2.5. Otimização de Alternativas de Desenvolvimento	31
2.6. Trabalhos Realizados	32
3 Técnicas da Inteligência Computacional	40
3.1. Introdução	40
3.2. Redes Neurais	40
3.2.1. Arquitetura <i>Multilayer Perceptron</i>	41
3.2.2. Redes Recorrentes	41
3.2.3. Algoritmo de Aprendizado <i>Back-Propagation</i>	42
3.2.4. Redes RBF	46
3.3. Modelos <i>Neuro-Fuzzy</i> Hierárquicos	49
3.3.1. Particionamento BSP	49
3.3.2. Modelo <i>Neuro-Fuzzy</i> Hierárquico BSP (NFHB)	50
3.4. Algoritmos Genéticos (AG)	53
3.4.1. Representação	54
3.4.2. Avaliação	55

3.4.3. Seleção e Reprodução	55
3.4.4. Operadores Genéticos	56
3.4.5. Parâmetros da Evolução	57
3.4.6. Avaliação de um algoritmo genético	59
3.4.7. Algoritmos Genéticos Distribuídos	59
4 Sistema Inteligente de Otimização	66
4.1. Introdução	66
4.2. Modelagem do Sistema	66
4.3. Algoritmo de Otimização	68
4.3.1. Representação das soluções no Cromossoma	68
4.3.2. Operadores Genéticos	69
4.3.3. Restrições na geração de soluções	71
4.4. Aproveitamento de Informações dos Mapas de Reservatório	71
4.5. Inferência de Curva de Produção	73
4.5.1. Simulador de reservatórios	74
4.5.2. Modelos de Aproximação.	74
4.5.3. Aproximação com Algoritmos Genéticos	78
4.5.4. Aprendizado com os modelos Neurais e <i>Neuro-Fuzzy</i> Hierárquico	79
4.6. Cálculo do Valor Presente Líquido (VPL)	81
4.6.1. Modelagem Econômica	82
4.7. Implementação do Sistema	85
4.7.1. Módulo de Dados	86
4.7.2. Módulo de Serviços	87
4.7.3. Módulo de Cliente	87
4.8. Uso de Ambientes Paralelos	87
4.8.1. Interface – Cenário	88
4.8.2. Interface – Avaliação	89
4.8.3. Controle de erros de comunicação	90
5 Estudos de Casos:	92
5.1. Reservatório 30x30x1	93
5.2. Reservatório 33x57x3	94
5.3. Aproximação da Função de produção	95
5.3.1. Testes do modelo de curva segmentada	95
5.3.2. Geração dos padrões de aprendizado	102
5.3.3. Experimentos de aprendizado dos modelos aproximadores	103

5.4. Experimentos com o Sistema de Otimização	111
5.4.1. Experimentos com reservatório 30x30x1	112
5.4.2. Experimentos com reservatório 33x57x3	120
5.4.3. Uso do módulo de inferência na otimização	130
5.4.4. Eficiência do uso de inferência de curvas de produção	132
5.4.5. Eficiência do uso de computação distribuída	133
5.5. Discussão	134
6 Conclusões e Trabalhos Futuros	136
6.1. Conclusões	136
6.2. Trabalhos Futuros	138
Bibliografia	140
Apêndice A – Simulador de Reservatórios IMEX	146
Apêndice B – Arquivos dos reservatórios utilizados	151
Apendice C – Arquitetura Corba	156

Lista de figuras

Figura 1. Balanço de material.	25
Figura 2. Malha de 2 (a) e 3 (b) dimensões.	27
Figura 3. Representação geral da arquitetura <i>multilayer perceptron</i> .	41
Figura 4. Rede recorrente de Elman.	42
Figura 5. Função Gaussiana para $c = 0, r = 1$	46
Figura 6. Função multiquadrática para $c = 0, r = 1$	47
Figura 7. Rede RBF típica	48
Figura 8. (a) Particionamento BSP. (b) árvore BSP correspondente	50
Figura 9. Célula <i>Neuro-Fuzzy</i> BSP (a) Interior e (b) Simplificada	51
Figura 10. Representação da célula NF-BSP em formato de rede neuro-fuzzy	51
Figura 11. Exemplo de Sistema NFHB e o seu respectivo particionamento	52
Figura 12. Procedimento básico do algoritmo genético	54
Figura 13. Cruzamento de um ponto.	56
Figura 14. Mutação binária.	57
Figura 15. Arquitetura <i>Master-Slave</i>	61
Figura 16. Pseudo-código: Algoritmo Genético Global	62
Figura 17. Pseudo-código do Modelo AG em Ilhas	63
Figura 18. Arquitetura de Populações quase-isoladas	63
Figura 19. Pseudo-código para o modelo AGs celulares.	64
Figura 20. Principais blocos do sistema otimizador proposto	67
Figura 21. Representação do Cromossoma	69
Figura 22. Mapa de qualidade normalizado e áreas de ativação de produtores	72
Figura 23. Mapa de aquífero normalizado e áreas de ativação de injetores	73
Figura 24. Bloco de inferência de curva de produção	73
Figura 26. Modelo de curva segmentada da curva de produção.	76
Figura 27. Cromossoma para a aproximação por AG.	78
Figura 28. Formato dos padrões de entrada e saída: pontos de curva.	80
Figura 29. Formato dos padrões de entrada e saída: curva segmentada.	81
Figura 30. Modelagem do Sistema de Otimização proposto.	85
Figura 31. Módulos de Implementação do Sistema Otimizador	86
Figura 32. Módulo destacado para distribuir no ambiente paralelo	88
Figura 33. Canais de comunicação usados na avaliação distribuída	90

Figura 34. Taxonomia do estudo de casos deste trabalho	92
Figura 35. Modelo de reservatório 30x30x1	93
Figura 36. Modelo do reservatório 33x57x3	94
Figura 37. Reservatório com a configuração 4 <i>five-spots</i> .	96
Figura 38. Curva de óleo acumulado: 4 <i>five-spots</i>	97
Figura 39. Curva de produção de óleo: 4 <i>five-spots</i>	97
Figura 40. Curva obtida e curva original do Exp-1: 4 <i>five-spots</i>	98
Figura 41. Curva de óleo acumulado: alternativa aleatória	99
Figura 42. Curva de produção de óleo: alternativa aleatória	99
Figura 43. Curva obtida e curva original do Exp-2: alternativa aleatória	100
Figura 44. Curva de óleo acumulado: cronograma de poços	100
Figura 45. Curva de produção diária de óleo: cronograma de poços	101
Figura 46. Resultados gráficos do Exp-3: cronograma de poços	101
Figura 47. Obtenção de padrões de entrada e saída	102
Figura 48. Curvas de evolução: reservatório 30x30x1 – Exp 1.	113
Figura 49. Disposição dos poços: reservatório 30x30x1 – Exp 1,	114
Figura 50. Curva de óleo acumulado: reservatório 30x30x1 – Exp 1,	114
Figura 51. Percentual de avaliação dos computadores – Exp 1.	115
Figura 52. Evolução: reservatório 30x30x1 – Exp 2.	116
Figura 53. Disposição dos poços: reservatório 30x30x1 – Exp 2.	117
Figura 54. Curva de óleo acumulado: reservatório 30x30x1 – Exp 2.	117
Figura 55. Curvas de evolução: reservatório 30x30x1 – Exp 3.	118
Figura 56. Disposição dos poços do 4- <i>five spots</i> inicial – Exp 3	119
Figura 57. Disposição dos poços após a evolução – Exp 3	119
Figura 58. Curvas de evolução: reservatório 33x57x3 – Exp 1.	121
Figura 59. Disposição de poços: reservatório 33x57x3 – Exp 1.	122
Figura 60. Curva de óleo acumulado: reservatório 33x57x3 – Exp 1.	122
Figura 62. Disposição dos poços: reservatório 33x57x3 – Exp 2.	124
Figura 63. Curva de óleo acumulado: reservatório 33x57x3 – Exp 2.	125
Figura 65. Disposição dos poços: reservatório 33x57x3 – Exp 3.	126
Figura 66. Curva de óleo acumulado: reservatório 33x57x3 – Exp 3.	127
Figura 67. Mapa de qualidade e mapa de aquífero – Exp 4.	128
Figura 68. Disposição dos poços: reservatório 33x57x3 – Exp 4.	128
Figura 69. Curva de óleo acumulado: reservatório 33x57x3 – Exp 4.	129
Figura 70. Curvas de evolução: reservatório 33x57x3 – Exp 4.	129
Figura 71. Curvas de evolução: módulo de inferência da produção – Exp 1.	131

Figura 72. Eficiência do uso de inferência de curvas.	132
Figura 73. Eficiência do uso da computação distribuída	133
Figura 74. Arquivos de entrada e saída do IMEX	148
Figura 75. Fluxo de requisições e respostas na arquitetura CORBA	158

Lista de tabelas

Tabela 1. Descrição dos parâmetros do modelo de curva segmentada	77
Tabela 2. Descrição dos parâmetros CAPEX.	83
Tabela 3. Descrição dos parâmetros OPEX.	84
Tabela 4. Parâmetros do cenário econômico.	85
Tabela 5. Restrições existentes nos parâmetros do modelo segmentado	95
Tabela 6. Parâmetros da evolução – modelo segmentado	96
Tabela 7. Taxas de operadores genéticos – modelo segmentado	97
Tabela 8. Parâmetros obtidos para o Experimento 1: 4 <i>five spots</i> .	98
Tabela 9. Resultados obtidos para o Exp- 2: alternativa aleatória.	99
Tabela 10. Resultados obtidos para o Exp-3: cronograma de poços.	101
Tabela 11. Parâmetros de aprendizado – Rede <i>feed-forward</i>	104
Tabela 12. Resultados da rede <i>feed-forward</i> – 2 poços	105
Tabela 13. Resultados da rede <i>feed-forward</i> – 8 poços	105
Tabela 14. Resultados da rede <i>feed-forward</i> – 10 poços.	105
Tabela 15. Parâmetros de aprendizado – Rede de Elman	106
Tabela 16. Resultados da rede Elman – 2 poços	106
Tabela 17. Resultados da rede Elman – 8 poços	106
Tabela 18. Resultados da rede Elman – 10 poços	106
Tabela 19. Resultados do modelo NFHB – 2 poços	107
Tabela 20. Resultados do modelo NFHB – 8 poços	107
Tabela 21. Resultados do modelo NFHB – 10 poços	108
Tabela 22. Resultados do modelo RBF – 2 poços	108
Tabela 23. Resultados da rede <i>feed-forward</i> – Curva segmentada	109
Tabela 24. Resultados da rede Elman – Curva segmentada	110
Tabela 25. Resultados do modelo NFHB – Curva segmentada	110
Tabela 26. Parâmetros relacionados às variáveis de mercado.	111
Tabela 27. Parâmetros CAPEX.	111
Tabela 28. Parâmetros OPEX.	112
Tabela 29. Parâmetros do AG: reservatório 30x30x1	112
Tabela 30. Restrições nas soluções do AG: reservatório 30x30x1	112
Tabela 31. Computadores utilizados: reservatório 30x30x1 – Exp 1	115
Tabela 32. Parâmetros do AG: reservatório 30x30x1 – semente inicial	118

Tabela 33. Parâmetros do AG: reservatório 33x57x3	120
Tabela 34. Restrições nas soluções do AG: reservatório 33x57x3	121
Tabela 35. Computadores utilizados: reservatório 33x57x3 – Exp 1	123
Tabela 36. Computadores utilizados: módulo de inferência da produção	130
Tabela 37. Tipos de dados existentes no arquivo .DAT	148
Tabela 38. Mapeamentos IDL para C++ para entidades	159
Tabela 39. Mapeamentos IDL para C++ para tipos conhecidos	159