



Rafael Lima de Oliveira

**Ajuste de Histórico em Modelos de Simulação de
Reservatórios por Algoritmos Genéticos Co-Evolutivos e
Geoestatística de Múltiplos Pontos**

Dissertação de Mestrado

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

Orientador: Prof. Marco Aurélio Cavalcanti Pacheco
Co-Orientador: Prof. Eugênio da Silva

Rio de Janeiro
Setembro de 2013



Rafael Lima de Oliveira

**Ajuste de Histórico em Modelos de Simulação de
Reservatórios por Algoritmos Genéticos Co-Evolutivos e
Geoestatística de Múltiplos Pontos**

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.

Prof. Marco Aurélio Cavalcanti Pacheco

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Eugênio da Silva

Co-orientador

UEZO

Prof. Douglas Mota Dias

Departamento de Engenharia Elétrica - PUC-Rio

Dr. Alexandre Anozé Emerick

Petróleo Brasileiro – Rio de Janeiro - Matriz

Dr. Ricardo Alexandre Passo Chaves

Petróleo Brasileiro – Rio de Janeiro - Matriz

Prof. José Eugenio Leal

Coordenador Setorial do Centro

Técnico Científico – PUC-Rio

Rio de Janeiro, 30 de Setembro de 2013

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

Rafael Lima de Oliveira

Graduou-se em Engenharia Elétrica com Ênfase em Sistemas e Computação pela Universidade do Estado do Rio de Janeiro (UERJ) em 2010.

Ficha Catalográfica

Oliveira, Rafael Lima de

Ajuste de histórico em modelos de simulação de reservatórios por algoritmos genéticos co-evolutivos e geoestatística de múltiplos pontos / Rafael Lima de Oliveira ; orientador: Marco Aurélio Cavalcanti Pacheco; co-orientador: Eugênio da Silva – 2013.

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

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2013.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Ajuste de histórico. 3. Algoritmos genéticos co-evolutivos. 4. Geoestatística de múltiplos pontos. I. Pacheco, Marco Aurélio Cavalcanti. II. Silva, Eugênio. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

A Deus toda honra e glória.
A minha esposa, irmão e amigos.
Aos meus pais por toda criação e educação.

Agradecimentos

A Deus, pela saúde, força e sabedoria.

Ao meu orientador, Marco Aurélio Pacheco pela oportunidade de poder fazer parte da equipe do Laboratório de Inteligência Computacional Aplicada (ICA), onde pude expandir meus conhecimentos.

Ao meu co-orientador, Eugênio da Silva, meu sincero agradecimento, pela extrema competência, dedicação, paciência e conhecimento compartilhado.

Ao CNPq e à PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

A minha esposa Shamara pelo apoio, carinho e incentivo nos momentos de desânimo.

Aos meus familiares pelo carinho e compreensão nos momentos de minha ausência.

Aos meus colegas de laboratório, por suas valiosas contribuições e importantes dicas.

Aos professores do Departamento de Engenharia Elétrica (DEE) e do Departamento de Engenharia Mecânica (DEM), pela dedicação e os importantes conhecimentos que me proporcionaram.

A minha sincera gratidão a todos que de forma direta ou indireta contribuíram para a conclusão deste trabalho.

*“Tantas vezes pensamos ter chegado,
Tantas vezes é preciso ir além...”*

Fernando Pessoa.

Resumo

Oliveira, Rafael Lima; Pacheco, Marco Aurélio Cavalcanti.; Silva, Eugênio da. **Ajuste de Histórico em Modelos de Simulação de Reservatórios por Algoritmos Genéticos Co-Evolutivos e Geoestatística de Múltiplos Pontos**. Rio de Janeiro, 2013. 133p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Na área de Exploração e Produção (E&P) de petróleo, uma das tarefas mais importantes é o estudo minucioso das características do reservatório para a criação de modelos de simulação que representem adequadamente as suas características. Durante a vida produtiva de um reservatório, o seu modelo de simulação correspondente precisa ser ajustado periodicamente, pois a disponibilidade de um modelo adequado é fundamental para a obtenção de previsões acertadas acerca da produção, e isto impacta diretamente a tomada de decisões gerenciais. O ajuste das propriedades do modelo se traduz em um problema de otimização complexo, onde a quantidade de variáveis envolvidas cresce com o aumento do número de blocos que compõem a malha do modelo de simulação, exigindo muito esforço por parte do especialista. A disponibilidade de uma ferramenta computacional, que possa auxiliar o especialista em parte deste processo, pode ser de grande utilidade tanto para a obtenção de respostas mais rápidas, quanto para a tomada de decisões mais acertadas. Diante disto, este trabalho combina inteligência computacional através de Algoritmo Genético Co-Evolutivo com Geoestatística de Múltiplos Pontos, propondo e implementando uma arquitetura de otimização aplicada ao ajuste de propriedades de modelos de reservatórios. Esta arquitetura diferencia-se das tradicionais abordagens por ser capaz de otimizar, simultaneamente, mais de uma propriedade do modelo de simulação de reservatório. Utilizou-se também, processamento distribuído para explorar o poder computacional paralelo dos algoritmos genéticos. A arquitetura mostrou-se capaz de gerar modelos que ajustam adequadamente as curvas de produção, preservando a consistência e a continuidade geológica do reservatório obtendo, respectivamente, 98% e 97% de redução no erro de ajuste aos dados históricos e de previsão. Para os mapas de porosidade e de permeabilidade, as reduções nos erros foram de 79% e 84%, respectivamente.

Palavras-chave

Ajuste de Histórico; Algoritmos Genéticos Co-Evolutivos; Geoestatística de Múltiplos Pontos

Abstract

Oliveira, Rafael Lima; Pacheco, Marco Aurélio Cavalcanti.; Silva, Eugênio da. **History Matching in Reservoir Simulation Models by Coevolutionary Genetic Algorithms and Multiple-Point Geostatistics.** Rio de Janeiro, 2013. 133p. MSc Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

In the Exploration and Production (E & P) of oil , one of the most important tasks is the detailed study of the characteristics of the reservoir for the creation of simulation models that adequately represent their characteristics. During the productive life of a reservoir, its corresponding simulation model needs to be adjusted periodically because the availability of an appropriate model is crucial to obtain accurate predictions about the production, and this directly impacts the management decisions. The adjustment of the properties of the model is translated into a complex optimization problem, where the number of variables involved increases with the increase of the number of blocks that make up the mesh of the simulation model, requiring too much effort on the part of a specialist. The availability of a computational tool that can assist the specialist on part of this process can be very useful both for obtaining quicker responses, as for making better decisions. Thus, this work combines computational intelligence through Coevolutionary Genetic Algorithm with Multipoint Geostatistics, proposing and implementing an architecture optimization applied to the tuning properties of reservoir models. This architecture differs from traditional approaches to be able to optimize simultaneously more than one property of the reservoir simulation model. We used also distributed processing to explore the parallel computing power of genetic algorithms. The architecture was capable of generating models that adequately fit the curves of production, preserving the consistency and continuity of the geological reservoir obtaining, respectively, 98% and 97% of reduction in error of fit to the historical data and forecasting. For porosity and permeability maps, the reductions in errors were 79% and 84%, respectively.

Keywords

History Matching; Coevolutionary Genetic Algorithms; Multiple-Point Geostatistics.

Sumário

1 Introdução	16
1.1 Contexto Geral	16
1.2 Motivações	17
1.3 Objetivos	18
1.4 Contribuições	18
1.5 Organização da Dissertação	19
2 Exploração e Produção de Petróleo	20
2.1 Engenharia de Reservatórios	20
2.2 Reservatório	20
2.2.1 Características do Reservatório	21
2.3 Modelo de Simulação	25
3 Fundamentação Teórica	27
3.1 Ajuste de Histórico	27
3.1.1 Ajuste de Histórico Manual	28
3.1.2 Ajuste de Histórico Automático	28
3.1.3 Ajuste de Histórico Assistido	29
3.2 Histórico	30
3.3 Algoritmos Genéticos	31
3.3.1 Estrutura Básica de Um Algoritmo Genético	32
3.3.1.1 Representação ou Codificação	34
3.3.1.2 Geração da População Inicial	34
3.3.1.3 Decodificação	35
3.3.1.4 Avaliação da População	35
3.3.1.5 Seleção dos Indivíduos	35
3.3.1.6 Operadores Genéticos	37
3.3.1.7 Parâmetros da Evolução	38
3.3.2 Algoritmo Genético Coevolutivo	39
3.3.2.1 Modelo Coevolucionário Cooperativo	41

3.3.2.2 Métodos de Seleção de Colaboradores	43
3.4 Geoestatística de Múltiplos Pontos	45
3.4.1 Algoritmo <i>FILTERSIM</i>	47
4 Modelagem e Implementação	54
4.1 Modelo de Solução I	54
4.1.1 Módulo de Inicialização	55
4.1.2 Módulo de Evolução	59
4.1.3 Módulo de Apresentação	64
4.2 Modelo Genético	65
4.2.1 Codificação e Decodificação	65
4.2.2 Função Objetivo	66
4.2.3 Operador de Cruzamento	67
4.2.4 Operador de Mutação I	68
4.2.5 Operador de Mutação II	71
4.3 Modelo de Solução II	72
4.4 Detalhes de Implementação	74
5 Estudo de Casos	82
5.1 Estudo de Caso I	82
5.1.1 Modelo de Simulação	82
5.1.2 Modelo de Solução I	87
5.1.3 Modelo de Solução II	93
5.2 Estudo de Caso II	99
5.2.1 Modelo de Simulação	99
5.2.2 Resultados	105
5.3 Estudo de Caso III	110
5.3.1 Modelo de Solução Adaptado	110
5.3.2 Análise I	110
5.3.3 Análise II	116
6 Conclusão e Trabalhos Futuros	126

Lista de Figuras

Figura 2.1: Disposição dos fluidos em um reservatório de petróleo	21
Figura 2.2: Ilustração de uma rocha porosa	22
Figura 2.3: Ilustração de uma rocha permeável	23
Figura 2.4: Ilustração da lei de Darcy	24
Figura 2.5: Malha vista em 2 e 3 dimensões	25
Figura 3.1: Progresso do ajuste de histórico assistido (Fonte, Silva 2011)	29
Figura 3.2: Ilustração de população contendo 3 indivíduos	32
Figura 3.3: Estrutura básica de um Algoritmo Genético	33
Figura 3.4: Exemplo de seleção por roleta	36
Figura 3.5: Cruzamento de um ponto	37
Figura 3.6: Mutação	38
Figura 3.7: Modelo coevolucionário cooperativo genérico (Adaptado de Potter & Jong, 2000)	42
Figura 3.8: Imagens de treinamento para propriedades categórica e contínua (Fonte: Silva, 2011)	47
Figura 3.9: Filtros a serem aplicados à imagem de treinamento (Fonte: Silva, 2011)	48
Figura 3.10: Aplicação do filtro à imagem de treinamento (Fonte: Silva, 2011)	49
Figura 3.11: Particionamento das distribuições de frequência (Fonte: Silva, 2011)	50
Figura 3.12: Padrões pertencentes a uma classe e seu protótipo correspondente (Fonte: Silva, 2011)	50
Figura 3.13: Fluxograma da etapa de classificação do algoritmo FILTERSIM (Fonte: Silva, 2011)	51
Figura 3.14: Fluxograma da etapa de simulação do algoritmo FILTERSIM (Fonte: Silva, 2011)	53
Figura 4.1: Modelo de Solução	55

Figura 4.2: Módulo de Inicialização	55
Figura 4.3: Fluxograma de inicialização das populações	57
Figura 4.4: Geração da população inicial (Fonte: Silva, 2011)	59
Figura 4.5: Módulo de Evolução	59
Figura 4.6: Fluxograma de integração com o distribuidor de tarefas	62
Figura 4.7: Módulo de Apresentação	64
Figura 4.8: Representação e decodificação do cromossoma (Fonte: Silva, 2011)	66
Figura 4.9: Operador Crossover (Fonte: Silva, 2011)	68
Figura 4.10: Distribuição das taxas de anulação em uma camada do reservatório (Fonte: Silva, 2011)	70
Figura 4.11: Cálculo da taxa de anulação adaptativa (Fonte: Silva, 2011)	71
Figura 4.12: Operador de Mutação II	72
Figura 4.13: Fluxograma de geração da população inicial Modelo de Solução II	74
Figura 4.14: Interface gráfica do aplicativo de ajuste de histórico	75
Figura 4.15: Exemplo de projeto criado no S-GeMS	76
Figura 4.16: Configurações do Algoritmo Genético Coevolutivo	77
Figura 4.17: Configurações dos Diretórios	77
Figura 4.18: Ferramenta de geração de arquivo do tipo INCLUDE	78
Figura 4.19: Ferramenta de conversão INCLUDE -> GSLIB e GSLIB -> INCLUDE	79
Figura 4.20: Ferramenta para o cálculo do RMSE de produção	80
Figura 4.21: Ferramenta para o cálculo do RMSE de mapa	80
Figura 4.22: Ferramenta para a geração das curvas de produção	80
Figura 5.1: Mapa de permeabilidade e porosidade com localização dos poços	83
Figura 5.2: Mapa de permeabilidade do caso base	84
Figura 5.3: Mapa de porosidade do caso base	85
Figura 5.4: Curvas de produção de água. Caso base e alvo	86
Figura 5.5: Curvas de produção de água. Caso base e alvo	87
Figura 5.6: Imagem de treinamento para permeabilidade e	87

porosidade, respectivamente

Figura 5.7: Curvas de produção de água. Caso otimizado – Estudo I – Modelo I	90
Figura 5.8: Curvas de produção de água. Caso otimizado – Estudo I – Modelo I	91
Figura 5.9: Mapa de permeabilidade do caso otimizado – Estudo I – Modelo I	92
Figura 5.10: Mapa de porosidade do caso otimizado – Estudo I – Modelo I	92
Figura 5.11: Curva de evolução da otimização – Estudo I – Modelo I	93
Figura 5.12: Curvas de produção de água. Caso otimizado – Estudo I – Modelo II	95
Figura 5.13: Curvas de produção de água. Caso otimizado – Estudo I – Modelo II	96
Figura 5.14: Mapa de permeabilidade do caso otimizado – Estudo I – Modelo II	97
Figura 5.15: Mapa de porosidade do caso otimizado – Estudo I – Modelo II	97
Figura 5.16: Curva de evolução da otimização – Estudo I – Modelo II	98
Figura 5.17: Localização dos poços no modelo PUNQ_S3_MOD	100
Figura 5.18: Mapa de permeabilidade do caso alvo	100
Figura 5.19: Mapa de porosidade do caso alvo	101
Figura 5.20: Mapa de permeabilidade do caso base	102
Figura 5.21: Mapa de porosidade do caso base	102
Figura 5.22: Curvas de produção de água. Caso base e alvo – Estudo II	103
Figura 5.23: Curvas de produção de água. Caso base e alvo – Estudo II	104
Figura 5.24: Imagem de treinamento para permeabilidade – Estudo II	104
Figura 5.25: Imagem de treinamento para porosidade – Estudo II	105
Figura 5.26: Curvas de produção de água do caso otimizado – Estudo II	107
Figura 5.27: Curvas de produção de água do caso otimizado –	108

Estudo II	
Figura 5.28: Mapa de permeabilidade do caso otimizado – Estudo II	108
Figura 5.29: Mapa de porosidade do caso otimizado – Estudo II	109
Figura 5.30: Curva de evolução da otimização – Estudo II	109
Figura 5.31: Mapa de permeabilidade do caso base – Estudo III –	112
Análise I	
Figura 5.32: Imagem de Treinamento – Estudo III – Análise I	113
Figura 5.33: Curvas de produção de água do caso otimizado –	113
Estudo III – Análise I	
Figura 5.34: Curvas de produção de água do caso otimizado –	114
Estudo III – Análise I	
Figura 5.35: Mapa de permeabilidade de caso otimizado – Análise I	115
Figura 5.36: Curva de evolução da otimização – Estudo III – Análise I	116
Figura 5.37: Mapa de permeabilidade do caso alvo – Estudo III –	117
Análise II	
Figura 5.38: Mapa de permeabilidade do caso base – Estudo III –	118
Análise II	
Figura 5.39: Curvas de produção do caso base – Estudo III – Análise	119
III	
Figura 5.40: Curvas de produção do caso base – Estudo III – Análise	120
II	
Figura 5.41: Imagem de Treinamento – Estudo III – Análise II	121
Figura 5.42: Curvas de produção de água do caso otimizado –	122
Estudo III – Análise II	
Figura 5.43: Curvas de produção de água do caso otimizado –	123
Estudo III – Análise II	
Figura 5.44: Mapa de permeabilidade do caso otimizado – Estudo III	124
– Análise II	
Figura 5.45: Curva de evolução da otimização – Estudo III – Análise I	124