

6º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

Estratégias Híbridas Global/Local para Gerenciamento Ótimo da Injeção de Água em Reservatórios de Petróleo

AUTORES:

Leonardo Correia de Oliveira; Silvana Maria Bastos Afonso; Bernardo Horowitz

INSTITUIÇÃO:

Universidade Federal de Pernambuco – UFPE

Este Trabalho foi preparado para apresentação no 6º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás- 6º PDPETRO, realizado pela a Associação Brasileira de P&D em Petróleo e Gás-ABPG, no período de 09 a 13 de outubro de 2011, em Florianópolis-SC. Esse Trabalho foi selecionado pelo Comitê Científico do evento para apresentação, seguindo as informações contidas no documento submetido pelo(s) autor(es). O conteúdo do Trabalho, como apresentado, não foi revisado pela ABPG. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões da Associação Brasileira de P&D em Petróleo e Gás. O(s) autor(es) tem conhecimento e aprovação de que este Trabalho seja publicado nos Anais do 6ºPDPETRO.

Estratégias Híbridas Global/Local para Gerenciamento Ótimo da Injeção de Água em Reservatórios de Petróleo

Abstract

The objective function on waterflooding management optimization problem in reservoir engineering is related to the oil production properly or to an economical design. The mathematical formulation of this problem leads to an objective function which presents multimodal characteristics. An adequate choice for its solution is to consider a global optimization strategy. As application of global methods to solve the reservoir management problem is generally limited by the convergence behavior, here genetic algorithms (GA) are combined with local strategies in a unique tool. The idea is to exploit the strengths of different algorithms and avoids their weakness. Moreover, as the search of the optimal solution will require multiple high costs numerical simulations, surrogate models using kriging methodology are built. A case study is analyzed in which different combination of global/local strategies are compared.

Introdução

De maneira geral, a função objetivo utilizada em problemas de otimização da exploração de um campo de petróleo está relacionada à produção propriamente dita ou à economia do projeto. A formulação matemática deste problema leva a uma função objetivo que apresenta características multimodais. Uma escolha adequada para solucionar o problema é considerar uma estratégia de otimização global. Como aplicação de métodos globais para resolver o problema de gerenciamento de reservatório é normalmente limitado pelo comportamento de convergência, aqui o algoritmo genético (*Genetic Algorithm* – GA) é combinado com estratégias locais em uma única ferramenta. A ideia é explorar a capacidade de diferentes algoritmos para superar suas desvantagens. Além disso, à medida que a busca pela solução ótima requer inúmeras e custosas simulações, o uso de modelos substitutos criados pela metodologia de krigagem é construído. Um caso é analisado no qual, diferentes combinações de estratégias globais/locais são comparadas.

Metodologia

De maneira geral, a função objetivo utilizada em problemas de otimização da exploração de um reservatório de petróleo está relacionada à produção propriamente dita ou a economia do projeto. Considerando a produção como foco principal, se busca a maximização da produção acumulada de óleo ou a manutenção da capacidade de uma linha de exploração pelo maior tempo possível, do ponto de vista da economia do projeto, a lucratividade é usualmente escolhida como indicador, onde se pode buscar a maximização do valor presente líquido (VPL), da taxa interna de retorno (TIR), ou algum outro índice econômico de interesse (Oliveira, 2006).

Experiências numéricas de otimização indicam que a tendência do processo de obtenção de soluções melhores aponta para topar a capacidade da plataforma (Wang et. al., 2002). No entanto, não há indicação teórica ou comprovação prática de que ter a plataforma trabalhando nos seus limites de capacidade durante todo o período de desenvolvimento do campo resultará, incontestavelmente, na melhor opção de operação. Com isso, formular o problema com variáveis de controle que resultem na operação da plataforma é algo natural a se considerar.

Neste trabalho, o VPL do fluxo de caixa da operação do reservatório será considerado como a função objetivo da otimização. A formulação geral adotada para o gerenciamento das vazões do campo é apresentada a seguir na Eq. 1.

$$\begin{aligned}
 \text{Maximizar: } \text{VPL} &= f(x_{p,t}, x_{\Delta,t,k}, \mathbf{u}) = \sum_{t=0}^T \left[\frac{1}{(1+d)^t} \cdot F_t(x_{p,t}, x_{\Delta,t,k}, \mathbf{u}) \right] \\
 \text{sujeito à: } \sum_{p \in P} x_{p,t} &\leq 1, \quad t = 1 \dots n_t \\
 \sum_{p \in I} x_{p,t} &\leq 1, \quad t = 1 \dots n_t \\
 \sum_{p \in P} x_{p,t} &\leq \sum_{p \in I} \frac{x_{p,t}}{\alpha} \leq 1, \quad t = 1 \dots n_t \\
 \sum_{k=1}^{n_t-1} x_{\Delta,t,k} &\leq 1 \\
 x_{p,t}^l &\leq x_{p,t} \leq x_{p,t}^u \\
 x_{\Delta,t,k}^l &\leq x_{\Delta,t,k} \leq x_{\Delta,t,k}^u, \quad k = 1 \dots n_t - 1
 \end{aligned} \tag{1}$$

Nas equações acima, d é a taxa de desconto aplicada ao capital, T é o tempo de concessão do projeto, e F_t é o fluxo de caixa no tempo t , os índices P e I se referem aos poços produtores e injetores, respectivamente, o vetor $\mathbf{u}$ representa parâmetros que não podem ser controlados como propriedades das rochas e dos fluidos no reservatório, preço do óleo e inflação, entre outras, e por fim, tem-se $x_{p,t}$ e $x_{\Delta,t,k}$ como as variáveis de projeto. A variável $x_{p,t}$ é a razão alocada no poço p no tempo t , e é dada por:

$$x_{p,t} = \frac{q_{p,t}}{Q_{prod,max}}, \quad p \in P; \quad x_{p,t} = \alpha \frac{q_{p,t}}{Q_{prod,max}}, \quad p \in I \tag{2}$$

onde $q_{p,t}$ é a vazão do poço p no tempo t , $Q_{prod,max}$ é a vazão máxima permitida de fluido no poço produtor e α é a razão determinada entre o óleo produzido e a água injetada, como apresentado a seguir:

$$\alpha = \frac{Q_{prod,max}}{Q_{inj,max}} \tag{3}$$

onde $Q_{inj,max}$ é a vazão máxima permitida de água injetada no poço injetor.

A variável $x_{\Delta,t,k}$ representa as variáveis relacionadas ao tempo onde as mudanças nas razões alocadas nos poços serão realizadas, e são definidas de forma normalizadas em função do tempo de concessão, como apresentado na equação a seguir:

$$x_{\Delta,t,k} = \frac{\Delta t_k}{T}, \quad k = 1 \dots n_t - 1 \tag{4}$$

Na formulação matemática considerada para os problemas de otimização que envolvem simulação de reservatórios, é comum encontrar funções que apresentam características multimodais bem como singularidades ao longo do domínio de projeto. Devido a tais características, se torna bastante indicado o uso de algoritmos evolucionários (*Evolutionary Algorithms* - EA), que têm como principais qualidades, a identificação de ótimos globais, ou próximos ao global, e a determinação de soluções em problemas discretos (Oliveira, 2008). Apesar das qualidades citadas dos EA's, algumas desvantagens tornam o uso dos mesmos restrito, pois necessitam de várias avaliações de funções até chegar à convergência.

No intuito de resolver o problema, foi utilizada uma metodologia que combina estratégias globais e locais de otimização, também conhecida como estratégia híbrida de otimização. Neste trabalho foi considerado um algoritmo de programação matemática acoplado ao EA. Dentre os EA's existentes, foi considerado o algoritmo genético (*Genetic Algorithm* - GA) (Goldberg, 1989) e o algoritmo local adotado na combinação híbrida foi o de programação sequencial quadrática (*Sequential Quadratic Programming* - SQP) (Michalewicz e Dasgupta, 1997).

Os GA's são uma família de modelos computacionais inspirados na genética clássica e foram introduzidos por John H. Holland nos anos 60 (Mitchel, 1999). O algoritmo básico de um GA segue os seguintes passos:

1. Uma população inicial é criada aleatoriamente e com os indivíduos é feita a avaliação da função a ser otimizada;
2. É realizada a seleção dos "pais" baseada na aptidão de cada indivíduo;
3. Os operadores genéticos do cruzamento (*crossover*) e mutação (*mutation*) são aplicados para gerar os novos indivíduos a partir dos "pais" selecionados;
4. A avaliação dos novos indivíduos é realizada;
5. A substituição dos indivíduos é feita com a finalidade de criar uma nova população;
6. Repete-se o processo, a partir do passo 2, até que os critérios de convergência ou limite de iterações permitidas sejam alcançados.

O algoritmo SQP, onde uma sequência de problemas quadráticos são resolvidos, e faz a aproximação da matriz Hessiana através do esquema BFGS (método Broyden-Fletcher-Goldfarb-Shanno) (Vanderplatts, 1984). Para otimização com o SQP, é considerada uma expansão de segunda ordem em série de Taylor da função $f(\mathbf{x})$ em $\bar{\mathbf{x}}$, de acordo com a Eq. 5:

$$f(\mathbf{x}) = f(\bar{\mathbf{x}}) + \nabla f(\bar{\mathbf{x}})^T \Delta \mathbf{x} + \frac{1}{2} \Delta \mathbf{x}^T \mathbf{H}(\bar{\mathbf{x}}) \Delta \mathbf{x} \quad 5$$

onde $\Delta \mathbf{x} = \mathbf{x} - \bar{\mathbf{x}}$, $\nabla f(\bar{\mathbf{x}})$ é o vetor gradiente de f em $\bar{\mathbf{x}}$, e $\mathbf{H}(\bar{\mathbf{x}})$ é a matriz Hessiana da Lagrangeana do problema.

É assumido que o vetor gradiente e a matriz Hessiana na Eq. 5 irão proporcionar uma boa aproximação da função verdadeira, especialmente se $\bar{\mathbf{x}}$ está próximo ao ponto ótimo.

Em suma, as principais etapas envolvidas no algoritmo SQP convencional são:

1. Estabelecer uma solução inicial $\mathbf{x}_0$;
2. Configurar uma aproximação inicial para a matriz Hessiana dos termos quadráticos da função objetivo;
3. Resolver o subproblema para encontrar a direção de busca;
4. Realizar uma busca linear para determinar o tamanho do passo na direção de busca;
5. Atualizar a solução;
6. Checa a convergência. Caso tenha sido atingida, pare, caso contrário, atualizar a Hessiana e volta ao passo 3.

A otimização com a estratégia híbrida é realizada em duas etapas. Na primeira etapa, o GA é responsável por encontrar a região onde se encontra o provável ótimo global, fornecendo a solução encontrada como ponto de partida para o algoritmo de programação matemática, responsável pela segunda etapa da otimização, que consiste em refinar a solução encontrada na primeira etapa. Os critérios de parada, bem como as características dos algoritmos que integram a estratégia híbrida, apresentam algumas configurações diferentes de quando são utilizados individualmente.

É característico de um problema que envolve a simulação de reservatório de petróleo, o alto custo computacional devido à simulação numérica exigida. Estratégias de aproximação são apontadas na literatura como um instrumento poderoso para superar esse tipo de problema. Dentre as técnicas de aproximação existentes, foi abordada a técnica de krigagem (Valente, 1982). Na estratégia híbrida, o modelo substituto é aplicado de maneiras diferentes em cada etapa no processo de otimização.

O primeiro passo para a construção do modelo substituto via krigagem é gerar pontos de amostragem que efetivamente preencham o espaço de projeto do problema de otimização. Os métodos para gerar amostras para modelos de ajuste são conhecidas coletivamente como plano de experimentos (*Design of Experiment* - DOE). Verificou-se que, para o problema específico de gerenciamento de injeção de água, abordado neste trabalho, a técnica de diagramação centralizada de Voronoi latinizada (*Latinized Centroidal Voronoi Tessellation* – LCVT) supera os outros em geral (Afonso et. al., 2008). Essa técnica é uma versão criada a partir da combinação das técnicas de diagramação centralizado de Voronoi (*Centroidal Voronoi Tessellation* – CVT) e de hipercubo latino (*Latin Hypercube Sampling* – LHS) (Romero et. al., 2006).

Ao se considerar a avaliação da função por modelos substitutos, uma nova consideração pode ser feita na segunda etapa da otimização híbrida. O modelo substituto é incorporado em um processo iterativo, que decompõe o problema original em vários subproblemas de otimização sequenciais, e cada subproblema é confinado em uma pequena região do espaço de projeto. Este processo é chamado de otimização com aproximação sequencial (*Sequential Approximation Optimization* - SAO) (Eldred et. al., 2004).

Quando usando o modelo substituto, o SAO é considerado no processo de busca local. O SAO decompõe o problema original de otimização em uma sequência de subproblemas de otimização, restritos a uma pequena sub-região do espaço de projeto. Um método de região de confiança é usado e a atualização do espaço das variáveis de projeto de cada subproblema (iteração do SAO). Matematicamente, cada subproblema k é definido como:

Maximizar: $\hat{f}^k(x)$

sujeito à: $\hat{g}_i^k(x) \leq 0, i = 1 \dots m$

$$x_l < x_l^k \leq x \leq x_u^k < x_u, \quad k = 0, 1, \dots, k_{\max}$$

onde: $x_l^k = x_c^k - \frac{\Delta^k}{2}$

$$x_u^k = x_c^k + \frac{\Delta^k}{2}$$

6

Na equação acima, $\hat{f}^k(x)$ e $\hat{g}_i^k(x)$ são as funções objetivo e restrições aproximadas, respectivamente, x_c^k , Δ^k , x_l^k e x_u^k são respectivamente, o ponto central, a extensão, e os limites inferior e superior da região de confiança na iteração k do SAO (Eldred et. al., 2004).

Para atualizar o tamanho da região de confiança, é considerado o esquema descrito em (Eldred et. al., 2004), que leva em consideração a precisão da função obtida no modelo substituto diante da função real. O processo envolvido segue os seguintes passos:

1. A função objetivo e as restrições são computadas no ponto central e nas amostras tomadas na sub-região;
2. O modelo substituto é construído na sub-região;
3. A otimização da função substituta na sub-região é realizada;
4. O valor da função objetivo e das restrições no modelo real é computado para o ponto encontrado no passo anterior;
5. A convergência é checada;
6. De acordo com a precisão da comparação entre o modelo real e o modelo substituto, a sub-região é movida/reduzida/ampliada;
7. É imposta uma consistência local;
8. A convergência geral da otimização é conferida. Se encontrada, o procedimento SAO é encerrado, caso contrário, retorna ao passo 3.

O subproblema de otimização é resolvido com o uso do SQP, como citado anteriormente.

De posse das estratégias de otimização e da técnica de construção de um modelo substituto, surgem diferentes abordagens a serem consideradas no tratamento do problema a ser resolvido. As abordagens híbridas consideradas seguem os seguintes esquemas:

- (1) $G_{HF}L_{HF}$ – GA e SQP executados considerando o modelo de alta fidelidade (uso direto do simulador);
- (2) $G_{LF}L_{HF}$ – GA executado num modelo substituto e SQP no modelo de alta fidelidade;
- (3) $G_{LF}L_{LF}$ – GA executado num modelo substituto seguido pelo SAO.

Resultados e Discussão

As características do problema são bem simples, pois a aplicação teve como propósito principal estudar e avaliar o comportamento do problema básico de otimização, dentro de condições muito simplificadas e de fácil controle. De geometria bastante simples, o problema tem como variáveis de controle as vazões dos poços e os tempos dos ciclos de controle. As variáveis podem ser apresentadas como indicados nas Eqs. 2 e 4.

O reservatório estudado neste problema possui as características apresentadas na Tabela 1. Na Figura 1 pode ser visto a disposição dos poços no reservatório (poços injetores e produtores) bem como a separação das regiões de acordo com a permeabilidade horizontal no reservatório. O valor da permeabilidade horizontal (k_h) na região do poço injetor I-1 tem o valor médio de 1000 mD, o k_h próximo ao poço produtor P-1 é 500 mD enquanto que próximo ao poço P-2 é de 1500 mD.

Tabela 1: Resumo das características do modelo estudado.

Malha de simulação	51 (510 m) x 51 (510 m) x 1 (4 m)
Porosidade	30%
Permeabilidade vertical (k_v)	10% de k_h
Compressibilidade da rocha a 200 kgf/cm ²	$5 \cdot 10^{-5} \text{ (kgf/cm}^2\text{)}^{-1}$
Contato entre fluidos	Sem contatos WOC e GOC
Pressão de saturação (P_{sat})	273 kgf/cm ²
Viscosidade a T_{res} , P_{sat}	0,97 cp
Razão gás-óleo de formação (RGOF)	115,5 m ³ /m ³ std




Figura 2 – Região de permeabilidade.

Para os poços produtores, o somatório das vazões dos mesmos não pode ultrapassar 40 m³/dia, e, a vazão individual não pode ultrapassar os 30 m³/dia. No caso do poço injetor, é considerada uma vazão máxima que não pode ultrapassar 44m³/dia. Com relação ao tempo de concessão para exploração do reservatório, o período total é de 16 anos.

Nos casos onde o GA realiza a busca utilizando o modelo substituto, a criação do mesmo é feita seguindo as regras baseadas em observações realizadas em estudos prévios (Afonso et. al., 2010). Para o modelo substituto de toda a região (aproximação global do domínio de projeto) será considerado um número de amostras igual a $5nvar$ ($nvar$ = número de variáveis do problema). No caso onde a otimização for conduzida pelo algoritmo de busca local sobre o modelo substituto considerando o esquema de região de confiança, será considerado um número de amostras igual a $2nvar + 1$, baseado nos estudos apresentados em (Horowitz et. al., 2009).

Para o problema estudado, 4 casos adotando diferentes tipos de estratégias para o gerenciamento serão considerados. A seguir é apresentado um resumo sobre cada caso.

- Caso 1 – operação em capacidade topada com os tempos para as mudanças nos poços fixados previamente;
- Caso 2 – operação em capacidade topada com os tempos onde ocorrem os controles nos poços considerados como variáveis do problema;
- Caso 3 – operação em capacidade não topada com os tempos para as mudanças nos poços fixados previamente;
- Caso 4 – operação em capacidade não topada com os tempos onde são realizados os controles nos poços considerados como variáveis do problema.

Nas tabelas 2 à 5, são apresentados os resultados obtidos pelas estratégias consideradas e comparadas com os resultados obtidos na literatura.

Tabela 2: Resultados encontrados no caso 1.

	$f(x^*)$ (10^6 U.M.)	Avaliações de função
Referência	1,4935	---
$G_{HF}L_{HF}$	1,4922	566
$G_{LF}L_{HF}$	1,4914	395
$G_{LF}L_{LF}$	1,4932	165

Tabela 3: Resultados encontrados no caso 2.

	$f(x^*)$ (10^6 U.M.)	Avaliações de função
Referência	1,4932	---
$G_{HF}L_{HF}$	1,4928	888
$G_{LF}L_{HF}$	1,4925	565
$G_{LF}L_{LF}$	1,4924	176

Tabela 4: Resultados encontrados no caso 3.

	$f(x^*)$ (10^6 U.M.)	Avaliações de função
Referência	1,7242	---
$G_{HF}L_{HF}$	1,1356	2056
$G_{LF}L_{HF}$	1,6738	386
$G_{LF}L_{LF}$	1,7227	441

Tabela 5: Resultados encontrados no caso 4.

	$f(x^*)$ (10^6 U.M.)	Avaliações de função
Referência	1,7331	---
$G_{HF}L_{HF}$	1,6170	1710
$G_{LF}L_{HF}$	1,6892	852
$G_{LF}L_{LF}$	1,6956	557

Dos resultados apresentados nas tabelas, se percebe que o valor obtido pelas estratégias foram satisfatórios, apesar dos resultados obtidos nos casos 3 e 4 apresentarem certa discrepância, em relação ao valor de referência. Este fato se atribui à dificuldade encontrada pelo GA de encontrar uma solução viável que servisse de ponto de partida para os algoritmos de busca local. Esta é uma das características dos EA's, que apresentam certa dificuldade em lidar com problemas restritos (problema formulado para os casos 3 e 4 apresentarem várias funções de restrições).

Conclusões

Neste trabalho, diferentes estratégias híbridas foram desenvolvidas e implementadas visando obter o gerenciamento ótimo de forma mais eficaz. Diferentes formas de gerenciamento foram formuladas e resolvidas. A estratégia híbrida $G_{LF}L_{LF}$, onde ambos estágios de busca emprega-se modelos substitutos (de baixo custo computacional) mostrou-se bastante eficiente ao se combinar precisão e redução de avaliações de função

Agradecimentos

Ao programa de recursos humanos, PRH-26, da ANP (Agência Nacional do Petróleo), a UFPE (Universidade Federal de Pernambuco) e a rede temática SIGER (Simulação e Gerenciamento de Reservatório de Petróleo) da UFPE, e ao CNPq.

Referências Bibliográficas

Afonso, S. M. B., Horowitz, B. and Oliveira, L. C. (2010), Waterflooding Management Through the Combination of Global and Local Optimization Strategies, In: EngOpt - 2nd International Conference on Engineering Optimization, Instituto Técnico Superior de Lisboa, Lisbon – Portugal.

Afonso, S. M. B., Horowitz, B. and Willmersdorf, R. B. (2008), Comparative Study of Surrogate Models for Engineering Problems. In: ASMO_UK/ISSMO INTERNATIONAL CONFERENCE ON ENGINEERING DESIGN OPTIMIZATION, 7th, Bath-UK

Eldred, M. S., Giunta, A. A. and Collis, S. S. (2004), Second-Order Corrections for Surrogate-Based Optimization with Model Hierarchies. Paper AIAA-2004-4457 in Proceedings of the 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, Albany, NY.

Goldberg, D. E. (1989), Genetic Algorithm in Search, Optimization and Machine Learning. Addison-Wesley Publishing Company, Reading, MA.

Horowitz, B., Afonso, S. M. B. and Mendonça, C. V. P. (2009), Rate Control Optimization of Waterflooding Management, In XXX CILAMCE – Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia.

Michalewicz, Z. and Dasgupta, D. (1997), (eds.) Evolutionary Algorithms in Engineering Applications, Springer Verlag.

Mitchel, M. (1999), An Introduction to Genetic Algorithms. The MIT Press.

Oliveira, L. C. (2008), Otimização Estrutural Utilizando o Algoritmo do Enxame de Partículas, Dissertação de Mestrado, Universidade Federal de Pernambuco, Recife, PE.

Oliveira, D. F. B. (2006), 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. Universidade Federal de Pernambuco, Recife, PE.

Romero, V. J., Burkardt, J. V., Gunzburger, M. D. and Peterson, J. S. (2006), Comparison of Pure and “Latinized” Centroidal Voronoi Tessellation Against Various Other Statistical Sampling Methods, Reliability Engineering and System Safety 91, p. 1266-1280.

Valente, J. (1982), Geomatematica: lições de geoestatística. Fundação Gorceix. Ouro Preto - MG.

Vanderplaats, G. N. (1984), Numerical Optimization Techniques for Engineering Design: with Applications, McGraw-Hill, New York.

Wang, p., Litvak, M. and Aziz, K. (2002), Optimization of Operation in Petroleum Fields, SPE 77658, Annual Technical Conference and Exhibition in San Antonio, Texas.