

5º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



Realização



TÍTULO DO TRABALHO:

Comparação de Técnicas de Modelação de Completações Inteligentes

AUTORES:

Bruna Araujo de Queiroz, Bernardo Horowitz, Leonardo Correia de Oliveira

INSTITUIÇÃO:

Universidade Federal de Pernambuco

COMPARAÇÃO DE TÉCNICAS DE MODELAÇÃO DE COMPLETAÇÕES INTELIGENTES (Tamanho: 12 – Fonte: verdana)

Abstract

The demand for intelligent wells containing flow control devices capable of improving oil production and reducing unwanted fluid production brings the need for implementations of a standardized well methodology with such equipment in reservoir simulation. The objective of this work is to compare modeling techniques of these devices, thus evaluating how each method behaves in controlling the valve openings in the producing well to maximize the Net Present Value (NPV) of the field. For this, a commercial numerical simulator coupled with a local search optimizer was used, using the quadratic sequential programming algorithm with the aid of sequential approximation optimization to solve the nonlinear problem. The results showed improvement in NPV and suggested good efficiency of the applied techniques.

Keywords: Intelligent Wells; Optimization; Devices.

1. INTRODUÇÃO

Otimizar a exploração de um reservatório de petróleo constitui em desenvolver uma estratégia rentável que permita produzir a maior quantidade de hidrocarbonetos possível, dentro dos limites físicos existentes. Bem como, diminuir a irrupção de água, uma vez que a sua elevada vazão pode ser um fator limitante para o desenvolvimento do campo, reduzir o número de intervenções nos poços, já que este processo inviabiliza temporariamente a produção e apresenta custos e riscos elevados, reduzir o risco do projeto, dado que em um planejamento do campo existem muitas incertezas com relação as características do reservatório. Como uma alternativa, surge o conceito de poços inteligentes.

Durlofsky e Aziz (2002) definiu os poços inteligentes como um poço não convencional, com unidade de controle remoto, cabos, conectores, penetradores, *clamps* e sistema de supervisão, instrumentação de fundo de poço (sensores, válvulas e dispositivos de controle de fluxo) instalado na tubulação de produção com *packers* que isolam segmentos do poço de forma a controlar o fluxo de forma independente através de cada uma das válvulas, de acordo com as informações recebidas pelos respectivos sensores.

Segundo Chen (2019), as válvulas de controle de fluxo (*Flow Control Valves – FCVs*), podem adotar diâmetros de aberturas que variam entre totalmente abertas ou totalmente fechadas, ou serem instaladas com a função somente de abrir e fechar. A falta de metodologia direta para modelar estas válvulas nos simuladores de reservatório, ou seja, a ausência de comandos específicos para representar e operar as válvulas dos poços inteligentes, leva a utilização de diversos artifícios indiretos presentes nos simuladores para representação do comportamento destas, como pode ser observado em Emerick (2007), Almeida (2007), Fonseca et al (2015), Granados (2018) e Chen (2019). Este artigo comparou técnicas de modelação da abertura de válvulas em um poço produtor, para avaliar a sua eficiência na maximização do valor presente líquido do campo, a partir de uma estratégia de otimização de busca local, contribuindo assim, para o estabelecimento de políticas de controles destes dispositivos e metodologias padronizadas.

2. METODOLOGIA

2.1 ESTRATÉGIAS ADOTADAS PARA CONTROLE DE FLUXO

Para modelar e simular o campo com poço produtor segmentado, utilizou-se o simulador comercial *black oil* IMEX (CMG, 2018), acoplado a um otimizador. As três técnicas de modelagem

adotadas e suas respectivas variáveis de controle, que representam o comportamento da abertura das FCVs, estão apresentadas na Tabela 1.

Tabela 1. Estratégias adotadas para modelação de um poço inteligente.

Casos	Descrição	Variável de Controle (VC)
1	Múltiplos Poços (MW)	Multiplicador do índice de produtividade
2	CLUMP	Multiplicador do índice de produtividade
3	Poços Segmentados Inteligentes (<i>Intelligent Segmented Well - iSegWell</i>) (CMG,2018a)	Diâmetros dos orifícios de cada válvula de controle de fluxo instalado no poço produtor
4	Poço Comum – Caso base	Não há variável de controle – Produção sem Otimização

Fonte: Autor (2019)

Para o caso 3, as FCVs foram representadas no cartão pela palavra-chave FCV-ORIF, onde os parâmetros exigidos e seus valores adotados seguem descritos na Tabela 2.

Tabela 2. Estratégias adotadas para o caso 2, características da FCV.

Parâmetro	Diâmetro interno	Diâmetro do orifício	Diâmetro externo	Temperatura de operação	Relação C_p/C_v	Coefficiente de descarga
Valor	0,064m	Variável	0,064 m	80 °C	1,4	0,85

Fonte: Autor (2019)

Os diâmetros dos orifícios foram normalizados para operar em um intervalo entre 0,1 e 1. A normalização foi feita dividindo o diâmetro do dispositivo da zona em questão, em determinado tempo, pelo diâmetro máximo permitido para o dispositivo (0,03m).

2.2 Formulação Padrão do Problema de Otimização

Para os casos descritos na Tabela 1, a função objetivo que se deseja maximizar é o VPL do reservatório, que segundo Horowitz et al, (2013)., representa uma função financeira com a finalidade de determinar o valor presente de pagamentos futuros, levando em consideração os valores adotados na Tabela 3. A formulação padrão do problema de otimização é dada por:

$$\text{Maximizar: } VPL(x_{z,t}) = \sum_{t=0}^T \left[\frac{1}{(1+d)^t} \cdot F_t(q_t(x_{z,t})) \right] \quad (2)$$

$$\text{Sujeito a: } x_{min} \leq x_{z,t} \leq x_{max}$$

Sendo o fluxo de caixa calculado por:

$$F_t(q_t(x_{z,t})) = \sum_{p=1}^{nP} (r_o q_{p,t}^o(x_{z,t}) - c_w q_{p,t}^w(x_{z,t})) - \sum_{l=1}^{nI} (c_{wi} q_{l,t}^w) \quad (2)$$

Onde d é a taxa de desconto aplicada ao capital, T é o tempo de concessão do projeto, F_t é o fluxo de caixa no tempo t , $x_{z,t}$ é a variável de projeto da zona z no intervalo de tempo t normalizada, x_{min} e x_{max} suas restrições de limites mínimo e máximo, respectivamente, nP é o número total de

poços produtores, r_o é o preço da unidade de óleo, $q_{p,t}^o$ é a vazão de óleo produzido do poço p no tempo t , $q_{p,t}^w$ é a vazão de água produzida do poço p no tempo t , c_w e c_{wi} são o custo da unidade de água produzida e de água injetada, respetivamente, nl é o número total de poços injetores, $q_{l,t}^w$ é a vazão de água injetada do poço l no tempo t .


Tabela 3. Valores utilizados no cálculo do VPL

Tipo	Valores
Preço de óleo	\$ 25
Custo da água produzida	\$ 5
Custo da água injetada	\$ 2
Taxa de desconto	0,093

Fonte: Granados et al. (2018).

2.3 Formulação do Problema

O tempo de concessão (dez anos) foi subdividido em cinco ciclos de controle (Figura 2) conforme feito em Granados et al. (2018), onde a cada ciclo uma avaliação das condições de produção do poço foi realizada para decidir os valores das variáveis.



Uma vez definida as variáveis de projeto, a função objetivo e estabelecer os ciclos de controle, o problema matemático a ser otimizado pode ser formulado como:

$$\begin{aligned} \text{Maximizar: } VPL(x_{z,t}) &= \sum_{t=0}^T \left[\frac{1}{(1+d)^t} \cdot F_t(q_t(x_{z,t})) \right] \\ \text{Sujeito a: } 0 &\leq x_{z,t} \leq 1,0 \quad (\text{Caso 1 e 2}) \end{aligned} \quad (3)$$

Para o caso 3:

$$\text{Sujeito a: } 0,1 \leq x_{z,t} \leq 1,0 \quad (\text{Caso 3})$$

2.4 Estratégia de Otimização

A otimização do problema não linear foi resolvida com a implementação da Otimização Sequencial por Aproximação (*Algorithm Approximation Sequential* – SAO) e com o algoritmo de busca local, Programação Sequencial Quadrática (*Sequential Quadratic Programming* – SQP), conforme usado por Horowitz et al, (2013).

Otimização Sequencial Por Aproximação (SAO): Usada para decompor o problema de otimização original em uma sequência de subproblemas menores, que são pequenas sub-regiões do domínio do projeto inicial, cada sub-região é administrada de forma adaptativa pela estratégia SAO (ALEXANDROV et al., 1998; ELDRED et al., 2004; HOROWITZ; BASTOS; MENDONÇA, 2013). As funções substitutas são criadas a partir de avaliações da função real e são operadas pelo algoritmo

de otimização nas pequenas regiões do espaço, denominado região de confiança (HOROWITZ et al, 2013). Matematicamente, podemos definir cada subproblema a ser resolvido pelo SAO como:

$$\begin{aligned}
 & \text{Minimizar } \hat{f}_k(x) \\
 & \text{Sujeito a: } \hat{h}_{i,k}(x) = 0, \quad (i = 1, 2, \dots, m) \\
 & \quad \quad \hat{g}_{j,k}(x) \leq 0, \quad (j = 1, 2, \dots, n) \\
 & \quad \quad \|x - x_{c,k}\| \leq \Delta_k \\
 & \quad \quad x_{\min} \leq x_{\min}^k \leq x \leq x_{\max}^k \leq x_{\max}
 \end{aligned} \tag{4}$$

Onde $\hat{f}_k(x)$, $\hat{h}_{i,k}(x)$ e $\hat{g}_{j,k}(x)$ são as funções substitutas da função objetivo, das m funções de restrição de igualdade e das n funções de restrição de desigualdade, respectivamente, para a iteração k , A e b representam a matriz e o vetor de termos independentes das restrições lineares, $x_{c,k}$ é o ponto central da região de confiança na iteração k , Δ_k é o tamanho da região de confiança na iteração atual, $x_{\min}$ e $x_{\max}$ são os limites mínimo e máximo, respectivamente, das variáveis de projeto. Cada subproblema representa uma iteração no SAO e, em cada iteração, os pontos candidatos a serem ótimos são validados com o modelo de fidelidade no centro da região de confiança, se houver uma diminuição considerável em algum desses pontos, então a região de confiança é reorientada nesse novo ponto (GIUNTA; ELDRED, 2000). A estratégia do SAO pode ser resumida:

1. Determinar o tamanho e o ponto inicial da região de confiança.
2. Calcular a função objetiva e as restrições na região de confiança para a construção do modelo substituto.
3. Construir o modelo substituto para a função objetivo e as restrições não-lineares.
4. Otimizar a função objetivo substitutiva sujeita às restrições substitutas não-lineares e as restrições lineares originais dentro da região de confiança.
5. Com o ponto ótimo encontrado no passo anterior, calcular a função objetivo e as restrições originais.
6. Verifique a convergência. Se o ponto ótimo é obtido, então finalizar o processo; caso contrário, continuar no passo 7.
7. Mover, aumentar, manter, e/ou reduzir a região de confiança de acordo com a precisão aproximada do modelo, em comparação com os valores da função objetivo e as restrições originais.
8. Impor a consistência (fator de correção) entre o modelo real e o aproximado
9. Retornar para o passo 3.


Programação Sequencial Quadrática (SQP): É uma metodologia iterativa que modela problemas não-lineares com base em uma dada solução $x^{(k)}$, por meio de um subproblema de programação quadrática (PQ). Resolve o subproblema PQ e usa essa solução para determinar a direção de busca e construir uma nova e melhor aproximação $x^{(k+1)}$. A metodologia é realizada de tal forma que cria uma sequência de soluções aproximadas de cada subproblema PQ, em cada iteração e converge para um mínimo local do problema não-linear (VANDERPLAATS, 1984). Este também conta com m funções de restrição de igualdade e das n funções de restrição de desigualdade. As principais etapas do algoritmo SQP são:

1. Definir um ponto inicial, $x^{(0)}$.
2. Configurar a aproximação inicial para a matriz Hessiana de acordo com os termos quadráticos da função objetivo.
3. Resolver o subproblema PQ para encontrar a direção de busca.
4. Realizar a busca linear para definir o tamanho do passo na direção de busca.
5. Atualizar a matriz Hessiana, utilizando o esquema BFGS, e atualizar a solução.
6. Verificar a convergência.
7. Se o mínimo local for encontrado, então parar o processo, caso contrário, retornar para o passo 3.

2.5 EXEMPLO

Neste trabalho foi utilizado o modelo estudado por Granados (2018), o qual é um reservatório sintético segmentado, composto de duas camadas produtoras com diferentes permeabilidades e uma barreira de fluxo entre elas (Figura 1). O modelo conta com um poço de injeção convencional de água e um poço produtor segmentado. A recuperação secundária foi aplicada durante os dez anos de concessão do campo. Para o poço injetor, assumiu-se uma vazão de injeção de água máxima de 2.000 bbl/dia e uma pressão máxima de injeção de 10.000 psi, sendo a vazão de injeção e a pressão de injeção as restrições primária e secundária de operação, respectivamente. Para o poço produtor, adotou-se como limites máximos de operação do poço uma vazão máxima de produção líquida de 1600 bbl/dia e uma pressão máxima de fundo de poço de 5900 psi, tendo a pressão e a vazão, respectivamente, como restrição primária e secundária.

Figura 1. Permeabilidade do modelo sintético.




Fonte: Adaptado de Granados (2018).

3. RESULTADOS E DISCUSSÃO

A Fig. 3(a) demonstra a produção acumulada para todos os casos citados na Tabela 1, onde verifica-se a eficiência da completação inteligente na melhoria do fator de recuperação do campo. A Fig. 3(b) e Fig. 3(c) mostram como as zonas produtoras se comportaram ao longo da simulação para o caso base, onde a produção é conjunta.

Figura 3. Condições de Produção. (a) Produção acumulada dos casos. (b) Produção de Água e Óleo da primeira camada produtora do caso base. (c) Produção de Água e Óleo da segunda camada produtora do caso base.




Fonte: Autor.

A Zona inferior, por ser mais permeável, tem maior facilidade para produzir, o que leva a irrupção prematura de água e redução na produção de óleo ao longo da simulação, como pode ser observado na Fig.3 (b). Já a zona superior, menos permeável, mantém a produção de óleo, mesmo que baixa, quase constante ao longo da simulação, e com corte de água igual a zero, como visto na Fig.3

(a). Pelas Fig 3(a) e Fig 3(b) constata-se que a zona inferior comanda a produção no poço, o que acaba limitando a zona superior.

Na Figura 4 (a,b,c,d) são apresentados os resultados obtidos para os casos otimizados. Para os três casos testados, a otimização reduziu o volume de água produzida, postergou a produção desse fluido indesejado e aumentou o volume de óleo recuperado, o que conduziu para o aumento do VPL do campo (Tabela 4). Pela Fig.3(a) e Fig4(c,f), o CLUMP, após a irrupção de água, apresentou uma eficiência menor no controle deste fluido indesejado.

Figura 4. Produção de Óleo, Água e Líquida das zonas produtoras. (a) Produção da primeira camada - iSegWell. (b) Produção da primeira camada - MW. (c) Produção da primeira camada - CLUMP. (d) Produção da segunda camada - iSegWell. (e) Produção da segunda camada - MW. (f) Produção da segunda camada - CLUMP.



Fonte: Autor.

Tabela 4. VPL encontrado para cada caso trabalhado.

Casos	VPL (10 ⁶ US\$ 10 ⁶)
Caso base (Poço Comum)	28,74
Caso 1 (Múltiplos Poços)	49,02
Caso 2 (CLUMP)	46,85
Caso 3 (iSegWell)	48,42

Fonte: Autor.

4. CONCLUSÕES

Os resultados encontrados sugerem uma boa eficiência para as diferentes técnicas aplicadas na modelação das válvulas de controle dos poços inteligentes. Todos os métodos conseguiram otimizar o valor presente líquido do campo, obtendo valores próximos, apesar do comportamento diferente das variáveis de controle ao longo do tempo de concessão do campo, mesmo partindo de conceitos diferentes. Para o trabalho em questão, o caso 1, com múltiplos poços, obteve maior VPL e O caso 2 obteve maior volume de água produzida, o que contribuiu para redução no valor do VPL. Os métodos simulados apresentaram uma maior diferença nos valores da produção de água do campo após a irrupção de água, comportamento este que deve ser estudado em trabalhos futuros.

5. AGRADECIMENTOS

Agradeço a CAPES e a *Energi Simulation* pelo suporte ao desenvolvimento desta pesquisa.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ALEXANDROV, Natalia M. et al. A trust-region framework for managing the use of approximation models in optimization. **Structural and Multidisciplinary Optimization**, [s. l.], v. 15, n. 1, p. 16–23, 1998.
- CHEN, Bailian; XU, Jianchun. Stochastic Simplex Approximate Gradient for Robust Life-Cycle Production Optimization: Applied to Brugge Field. **Journal of Energy Resources Technology**, [s.l.], v. 141, set. 2019.
- CMG. **iSEG WELL USER GUIDE Intelligent Segmented Well**. Calgary, Alberta: Computer Modelling Group Ltd, 2018. a.
- CMG. **IMEX User Guide Three-phase, Black-oil Reservoir Simulator**. Calgary, Alberta: Computer Modelling Group Ltd, 2018. b.
- DURLOFSKY, Louis J.; AZIZ, Khalid. Optimization of Smart Well Control. **SPE International Thermal Operations And Heavy Oil Symposium And International Horizontal Well Technology Conference**, p.1-2, nov. 2002. Society of Petroleum Engineers. <http://dx.doi.org/10.2118/79031-ms>.
- ELDRED, Michael S. et al. Second-order corrections for surrogate-based optimization with model hierarchies. **10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference**, [s. l.], p. 1–15, 2004.
- EMERICK, Alexandre Anozé; CUNHA, Ricardo. Production Optimization With Intelligent Wells. **SPE Latin American and Caribbean Petroleum Engineering Conference**, Buenos Aires, Argentina, 2007.
- FONSECA, Rahul; OLWIJN, Leeuwenburgh; VAN DEN HOF, Paul; JANSEN, Jan-Dirk. Improving the ensemble-optimization method through covariance-matrix adaptation. **SPE Journal**, 20(1):155–168, 2015. *Methods Eng.*, 109(13), pp. 1756–1776.
- GIUNTA, Anthony A.; ELDRED, Michael S. IMPLEMENTATION OF A TRUST REGION MODEL MANAGEMENT STRATEGY IN THE DAKOTA OPTIMIZATION TOOLKIT. **American Institute of Aeronautics and Astronautics**, [s. l.], n. c, 2000.
- GRANADOS, Kewin Passos. **GERENCIAMENTO ÓTIMO DA INJEÇÃO DE ÁGUA USANDO COMPLETAÇÕES INTELIGENTES**. 2018. 139 f. Dissertação (Mestrado) - Curso de Pós Graduação em Engenharia Civil, Engenharia Civil, Universidade Federal de Pernambuco, Recife, 2018. Cap. 5.
- HOROWITZ, Bernardo; AFONSO, Silvana Maria Bastos; MENDONÇA, Carlos Victor Paiva de. Surrogate based optimal waterflooding management. **Journal Of Petroleum Science And Engineering**, [s.l.], v. 112, p.206-219, dez. 2013.
- VANDERPLAATS, Garret N. **Numerical optimization techniques for engineering design: with applications**. New York (N. Y.): McGraw-Hill Ryerson, Limited, 1984.