

COMPARAÇÃO ENTRE METODOLOGIA DE OTIMIZAÇÃO GLOBAL E O MÉTODO DE GRADIENTES PARA AJUSTE DE HISTÓRICO ASSISTIDO

Célio Maschio¹ e Denis José Schiozer²

^{1,2}Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica
Departamento de Engenharia de Petróleo, Caixa Postal 6122
13.083-970, Campinas, SP
celio@dep.fem.unicamp.br
denis@dep.fem.unicamp.br

Resumo – O processo de ajuste de histórico consiste no aperfeiçoamento de um modelo de simulação com base em dados observados durante a produção de um campo de petróleo. Trata-se da inclusão de dados dinâmicos no processo de caracterização do reservatório. O processo de ajuste pode ser feito de forma manual ou assistida por um programa através de algoritmos de otimização. Diversas metodologias de ajuste de histórico assistido têm sido propostas. Elas podem ser classificadas em dois grandes grupos: metodologia de otimização global e metodologia de otimização local. A primeira é baseada apenas no valor da função objetivo e a segunda requer o cálculo de gradientes da função objetivo em relação aos parâmetros de ajuste. O objetivo deste trabalho é avaliar duas metodologias de ajuste de histórico assistido, uma baseada em cálculo de gradientes e a outra baseada em otimização global. Um modelo sintético de reservatório heterogêneo, com características próximas de um caso real, é utilizado para avaliar as metodologias e os resultados permitem apontar algumas vantagens e desvantagens de cada metodologia.

Palavras-Chave: Engenharia de reservatórios, ajuste de histórico de produção, ajuste de histórico assistido, métodos de otimização

Abstract – History matching process consists of the improvement of a simulation model based on observed data during the production of a petroleum field. It implies in the addition of dynamic data in the reservoir characterization process. The history matching process can be manual or assisted by a program using optimization algorithm. Several assisted history matching methodology have been proposed. They can be classified in two main categories: global optimization and local optimization. The former is based only on the objective function value and the latter requires the computation of gradients of the objective function with respect to the matching parameters. The objective of this work is to evaluate two assisted history matching methodologies, one based on gradients and other based on global optimization. A heterogeneous synthetic reservoir model, with characteristics similar to a real case, is used in order to evaluate the methodologies and the results allow pointing out some advantages and disadvantages of each methodology.

Keywords: Reservoir engineering, production history matching, assisted history matching, optimization methods

1. Introdução

O processo de ajuste de histórico é um processo de otimização que consiste na calibração de um modelo de simulação com base nos dados de produção e pressão observados durante a produção do campo. Além dos dados de produção e pressão, outras informações podem ser utilizadas no processo, como por exemplo, dados de sísmica (mapas de saturação, por exemplo) e dados provenientes de testes de poços. O ajuste de histórico é um processo inverso no qual as variáveis (ou propriedades do reservatório) de interesse são perturbadas de forma que o modelo reproduza os dados observados. A maneira convencional de se realizar o processo é de forma manual, ou seja, todo o fluxo de trabalho envolvido, tal como alteração das propriedades no modelo de simulação, execução das simulações, avaliação da qualidade de cada iteração, etc, é toda feita manualmente. Por outro lado, o processo de ajuste assistido é aquele onde as tarefas manuais são automatizadas. Existe na literatura uma grande quantidade de métodos e algoritmos de otimização e metodologias para ajuste de histórico assistido. Porém, uma grande parte deles apresenta restrições e limitações, sendo aplicada apenas a alguns casos específicos ou a uma família de casos específicos.

De uma forma geral, os métodos de otimização para ajuste de histórico podem ser classificados em duas grandes categorias: métodos baseados em gradientes e métodos de otimização global. Nos métodos baseados em gradiente realiza-se o cálculo dos gradientes internos pelo simulador de fluxo com respeito a cada parâmetro de ajuste, em cada passo de tempo da simulação. Pode-se dizer que nesses métodos, o algoritmo de otimização interage com a simulação de fluxo internamente. Já os métodos globais “enxergam” a simulação externamente, de forma que qualquer decisão é tomada com base em quantidades calculadas ao fim de cada simulação, ou seja, só depende do valor da função objetivo. Dentre os diversos métodos de otimização global propostos na literatura, pode-se citar o algoritmo genético (Schulze-Riegert, 2001; Romero, 2000), *simulated annealing* (Quenes, 1993) e algoritmo de busca direta (Maschio e Schiozer, 2004).

Os métodos baseados em gradientes também utilizam um algoritmo de otimização para encontrar um mínimo da função objetivo. Dentre os mais utilizados, pode-se citar o algoritmo de Levenberg-Marquardt (Arenas, 2001), o método Gradzone (Brun, 2001).

Seja qual for o método ou o algoritmo de otimização, existem vantagens e desvantagens. Os métodos baseados em cálculo de gradientes geralmente possuem a vantagem de apresentarem uma convergência mais rápida. Mas, dependendo do caso, o método baseado em gradientes pode levar o algoritmo a ficar “preso” em uma região muito restrita do espaço de soluções, com incrementos muito pequenos nos parâmetros de ajuste, levando a um acréscimo desnecessário do número de iterações.

2. Metodologias avaliadas

Neste trabalho foram avaliadas duas metodologias diferentes de ajuste de histórico assistido, sendo que uma delas utiliza o método de gradientes (que será denominada de Metodologia 1) e a outra utiliza o método de otimização global (que será denominada de Metodologia 2).

2.1 Método gradiente (Metodologia 1)

O método baseado em cálculo de gradiente avaliado neste trabalho faz parte de um programa comercial de ajuste de histórico assistido. A função objetivo (F_{RMS}) é definida da seguinte forma:

$$F_{RMS} = \sqrt{\frac{2F}{m}}, \text{ sendo } F = \frac{\alpha}{2} \mathbf{r}^T \mathbf{r} + \frac{\beta}{2} \mathbf{s}^T \mathbf{C}_s^{-1} \mathbf{s} + \gamma \mathbf{f}_{prior} \quad (1)$$

onde m é o número total de dados observados, α , β e γ são pesos globais atribuídos a cada termo da função objetivo; $\mathbf{r}$ é o vetor de resíduos dos dados de produção observados (do tipo vazão, pressão, etc). A rigor, é a diferença entre o dado observado e o simulado; $\mathbf{s}$ é o vetor de resíduos de dados do tipo mapa de saturação de água/óleo, extraídos de um levantamento sísmico, por exemplo; $\mathbf{C}_s$ é a matriz de correlação entre os resíduos dos dados de sísmica observados; $\mathbf{f}_{prior}$ é o termo da função objetivo que permite atribuir informações a respeito das distribuições estatísticas dos parâmetros. Este termo reflete a medida da incerteza dos parâmetros do reservatório. Além do desvio-padrão, outras informações provenientes de caracterizações geoestatísticas podem ser incorporadas (informações geoestatísticas não são geradas pelo programa).

Existem vários parâmetros de controle cuja calibração é importante e depende das características de cada caso. Os parâmetros de controle, que têm como objetivo evitar simulações desnecessárias, estão associados basicamente à função objetivo e aos parâmetros de ajuste. Os principais são: (1) Valor mínimo da função objetivo ao final do processo; (2) Número máximo de iterações; (3) Valor mínimo do decremento da função objetivo: quando a redução da função objetivo for menor do que este valor mínimo em duas iterações consecutivas, o processo é encerrado. Este parâmetro pode ser chamado também de tolerância da função objetivo; (4) Valor máximo e mínimo permitido na perturbação dos parâmetros de ajuste: a perturbação em um determinado parâmetro de ajuste é dimensionada automaticamente durante o processo e é proporcional ao gradiente relativo àquele parâmetro na iteração anterior. Esses parâmetros podem ser configurados para evitar variações muito bruscas ou muito pequenas nos parâmetros de ajuste.

De uma forma geral, a configuração dos parâmetros de controle requer uma análise prévia do problema, como por exemplo, valor inicial da função objetivo, valor final (ou valor mínimo) da função objetivo aceitável. Quanto ao valor final da função objetivo ele pode ou não ser atingido, em função das características do problema e da escolha dos

parâmetros de ajuste. O algoritmo de otimização trabalha em um espaço contínuo, cuja representação esquemática está mostrada, de forma simplificada, na (Figura 1-a). O incremento em cada parâmetro, reaperesentado na figura por dx e dy , depende do gradiente em relação ao parâmetro.

2.2 Método de otimização global (Metodologia 2)

O método de otimização global avaliado neste trabalho utiliza um algoritmo de busca direta. Neste algoritmo, o espaço de soluções é formado pela discretização dos parâmetros de ajuste, sendo que cada parâmetro corresponde a um eixo desse espaço. Para cada parâmetro é atribuído um valor mínimo e um valor máximo e um número de intervalos. Na Figura 1-b é mostrada uma representação esquemática do algoritmo para dois parâmetros genéricos, formando um espaço de soluções bi-dimensional. O algoritmo funciona através de sucessivas buscas exploratórias e lineares. A primeira busca exploratória se dá em torno de um ponto inicial (ponto 0), sendo que o ponto de menor função objetivo (ponto 1 em azul) determina a direção da busca linear que ocorre em seguida. O ponto de menor FO (ponto 2 em azul) da primeira busca linear é o ponto em torno do qual uma nova busca exploratória é realizada. O algoritmo termina em uma busca exploratória quando os valores da FO nos pontos explorados forem todos maiores do que ponto em torno do qual ocorreu a busca exploratória. No exemplo da Figura 1-b o ponto de mínimo encontrado é o ponto 4 em verde.

A idéia desta técnica, ou desse algoritmo, é o fato de que apenas valores discretos são atribuídos aos parâmetros. Assim, ao invés de se trabalhar com uma tolerância em relação à função objetivo, trabalha-se diretamente com a variação dos parâmetros. Geralmente é mais intuitivo se saber qual a variação razoável para um determinado parâmetro, do que a resposta de uma perturbação no parâmetro sobre a função objetivo. Considerando, por exemplo, um mapa de permeabilidade absoluta variando entre 1000 e 7000 mD, é razoável supor que uma variação de aproximadamente 200 mD seria suficiente para uma devida avaliação da influência do parâmetro.




Figura 1 - Representação esquemática do algoritmo de busca direta

A função objetivo (F) é definida da seguinte forma:

$$F = \sqrt{\frac{\sum_{j=1}^M w_j \sum_{i=1}^N (d_{obs}^i - d_{sim}^i)^2}{m}} \quad (2)$$

sendo M o número de funções objetivo parciais, ou série de dados (vazão de óleo, corte de água de vários poços, por exemplo), w_j é o peso aplicado a cada função objetivo parcial, d_{obs} e d_{sim} são os dados observados e simulados, respectivamente, N é o número de dados relativo a cada função objetivo parcial e m é o número total de dados observados. Este cálculo é o mesmo obtido pela equação (1), considerando que sejam levados em conta apenas dados de produção.

3. Aplicação

O caso estudado neste trabalho foi extraído do modelo 2 do décimo projeto comparativo da SPE (SPE 10). O modelo original é composto por uma malha de 1.122.000 blocos ($60 \times 220 \times 85$). Maiores detalhes do modelo podem ser encontrados em Christie (2001). Inicialmente foram extraídas 10 camadas (camadas 71 a 80) do modelo original. Esta porção do reservatório originou o modelo de referência utilizado, composto por $60 \times 220 \times 10$ blocos (132000 blocos). Os dados considerados como histórico foram obtidos através da simulação deste modelo de referência. O período de histórico considerado foi de 10 anos. Foram utilizados 6 poços produtores e 3 injetores de água.

O modelo inicial (modelo base) a ser ajustado foi obtido inicialmente pela extração de 10 camadas de outra região do reservatório original (camadas 11 a 20). Esta região apresenta propriedades petrofísicas (porosidade, permeabilidade horizontal e vertical) diferentes da região de onde foram extraídas as camadas para o modelo de referência. O modelo original é bastante heterogêneo e existem duas regiões distintas com relação às formas e distribuição de canais e regiões de alta porosidade e permeabilidade. O procedimento seguinte foi a realização de um

processo de transferência de escala para a redução do tamanho do modelo base. O modelo base de 60 x 220 x 10 blocos foi reduzido em 3 vezes na direção x, 5 vezes na direção y e 2 vezes na direção z, ou seja, cada bloco do modelo grosseiro passou a representar um conjunto de 3 x 5 x 2 blocos do modelo inicial (antes da transferência de escala). Para a transferência de escala da porosidade foi utilizada a média aritmética e para as permeabilidades horizontal e vertical foi utilizado o método DP, proposto por Maschio e Schiozer (2003).

4. Procedimentos de avaliação

Procedimento 1 (teste de mínimos locais): Para avaliar as duas metodologias com relação à presença de mínimos locais na função objetivo, foi gerado um conjunto de soluções utilizando 21 multiplicadores de volume poroso (MULT PV) variando entre 0.4 e 1.6 com intervalos constantes e 21 multiplicadores de permeabilidade horizontal (MULT PERMX) variando entre 0.05 e 3.5 com intervalos constantes, gerando um total de 441 simulações. O intuito deste procedimento foi avaliar o comportamento das metodologias utilizadas com relação a mínimos locais. A função objetivo foi composta da seguinte forma:

$$F = \sqrt{\frac{\sum_{p=1}^6 \sum_{i=1}^{60} (d_{obs}^i - d_{sim}^i)^2_{WCUT} + \sum_{p=1}^6 \sum_{i=1}^{60} (d_{obs}^i - d_{sim}^i)^2_{BHP}}{720}} \quad (3)$$

sendo que 6 é o número de poços produtores, 60 é o número de dados (pontos) observados, WCUT é o corte de água dos poços e BHP a pressão de fundo de cada poço.

Uma vez gerados todos os pontos do conjunto de soluções descrito anteriormente, foi feito um ajuste utilizando cada uma das metodologias. Para o ajuste, foram usados os mesmos extremos dos parâmetros usados para gerar o conjunto de soluções (MULT PV entre 0.4 e 1.6 e MULT PERMX entre 0.05 e 3.5) e em cada metodologia foi usado o mesmo ponto inicial. Os procedimentos 2 e 3, descritos abaixo, descrevem outro processos de ajuste independentes deste realizado para teste de mínimos locais.

Procedimento 2: Foram realizados outros processos de ajuste utilizando a permeabilidade horizontal das 5 camadas do modelo (5 parâmetros). Para os 5 parâmetros foi usado um extremo mínimo de 0.25 e um extremo máximo de 3.0. Na Metodologia 1 foram testados 3 valores para a tolerância da função objetivo: 0.1%, 1.0% e 3.0%; enquanto na Metodologia 2 foram testados 3 níveis de discretização dos parâmetros: 10, 20 e 30 intervalos.

Procedimento 3: O procedimento 3 teve como objetivo avaliar as metodologias em relação ao número de parâmetros de ajuste. Foram adicionadas as permeabilidades verticais das 5 camadas do modelo, com multiplicadores variando entre 0.25 e 3.0, totalizando 10 parâmetros. Tanto no procedimento 2 quanto no 3, foi feito o ajuste do corte de água dos 6 poços produtores, sendo que a função objetivo foi composta da seguinte forma:

$$F = \sqrt{\frac{\sum_{p=1}^6 \sum_{i=1}^{60} (d_{obs}^i - d_{sim}^i)^2_{WCUT}}{360}} \quad (4)$$

Foi realizada uma análise de sensibilidade (não apresentada) e verificou-se que, de uma forma geral, todos os parâmetros exercem influência na função objetivo, justificando a inclusão dos parâmetros no ajuste.

Número de simulações: O número de simulações apresentados nos resultados são simulações equivalentes que representam o esforço computacional referente a cada metodologia. Para a Metodologia 1, cada iteração do processo de ajuste é uma simulação com cálculo de gradientes. O cálculo dos gradientes incorpora um custo adicional em relação a uma simulação simples. Este custo depende do número de parâmetros e da natureza de cada caso. Geralmente, cada parâmetro aumenta em torno de 20 % o tempo de simulação. Multiplicando-se o fator de acréscimo pelo número de iterações, obtém-se o número de simulações equivalentes do processo de ajuste. Na Metodologia 1, as simulações são realizadas em série em uma única máquina.

A Metodologia 2 utiliza simulações simples apenas. Porém, as simulações são realizadas em paralelo em uma rede de computadores. A distribuição das simulações em uma rede promove uma aceleração do processo. Para obter o número de simulações equivalentes, multiplica-se o fator de aceleração (*speedup*) pelo número total de simulações de cada processo de ajuste.

5. Resultados

Na Figura 2-a mostra-se a superfície da função objetivo obtida com a geração do conjunto de soluções. Observa-se que há duas regiões de mínimo bem definidas. O mínimo global ($F = 18.3$) corresponde ao ponto: MULT PV = 0.5 e MULT PERMX = 3.5. O ponto encontrado usando-se Metodologia 1 é MULT PV = 1.4 e MULT PERMX = 0.09 (ponto branco na figura), cujo valor da função objetivo é 37.7. Notar que o ponto não pertence exatamente a um determinado nó da malha, pois o método é contínuo. Já o ponto encontrado usando-se a Metodologia 2 é o ponto marcado em amarelo, que corresponde ao mínimo global da função objetivo.




Figura 2 - Superfície da função objetivo (a) e pontos encontrados usando-se as duas metodologias (b)

Na Figura 3, está a evolução da função objetivo ao longo do número de simulações para a Metodologia 1, variando-se a tolerância (a) e variando-se o número de parâmetros (b). Pode-se observar que usando uma tolerância de 0.1 %, o número de simulações chegou a 60, porém, nota-se que praticamente não houve redução da função objetivo a partir da 24ª simulação, onde o processo chegou ao fim usando um tolerância de 3%, mostrando que para este caso esta seria uma tolerância adequada. A comparação entre o número de parâmetros de ajuste (5 e 10 parâmetros) para a Metodologia 1 (apresentada na Figura 3-b) mostra que para 10 parâmetros foram necessárias 47 simulações, enquanto que para 5 parâmetros, foram necessárias 60. Paralelamente, pode-se observar que a redução da função objetivo foi maior quando se usou 10 parâmetros, o que explica o fato de ter usado menos simulações, pois a tolerância da função objetivo foi atingida mais rapidamente.

Na Figura 4-a mostra-se a evolução da função objetivo com o número de simulações para 3 diferentes discretizações dos parâmetros (10, 20 e 30 intervalos) para a Metodologia 2. Pode-se notar que a melhor solução foi usando 10 parâmetros, pois foram necessárias 38 simulações, enquanto que usando 20 intervalos foram necessárias mais de 50 e usando 30 intervalos foram necessárias quase 70, e a redução da função objetivo foi praticamente a mesma. Na Figura 4-b mostra-se a evolução da função objetivo para 5 e 10 parâmetros de ajuste (ambas as situações com 10 intervalos).




Figura 3 - Variação da função objetivo com 5 parâmetros (a) e para 5 e 10 parâmetros de ajuste (b)




Figura 4 - Variação da função objetivo com 3 diferentes discretizações (a) e para 5 e 10 parâmetros de ajuste (b)

Na Figura 5 estão os resultados do ajuste do corte de água para dois poços, para as duas metodologias. O resultado é para o ajuste com 10 parâmetros em ambas as metodologias.




Figura 5 - Exemplos de ajuste do corte de água de 2 poços

6. Conclusões

Este trabalho mostrou algumas vantagens e desvantagens das metodologias de ajuste de histórico assistido avaliadas. Com relação à qualidade do ajuste, as duas metodologias apresentaram, de maneira geral, desempenhos semelhantes. A Metodologia 1 se mostrou mais eficiente, sob o aspecto de esforço computacional, em relação ao aumento do número de parâmetros de ajuste, quando comparado com a Metodologia 2. Porém, a Metodologia 2 se mostrou mais robusta em situação onde há mais de um mínimo local na função objetivo. A Metodologia 1 requer um conhecimento prévio da tolerância da função objetivo para funcionar adequadamente. Já na Metodologia 2, o conhecimento da tolerância deve ser em relação à variação dos parâmetros de ajuste.

7. Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq/PROSET), Finep/CTPETRO e Petrobras pelo suporte financeiro.

8. Referências

- ARENAS, E.; VAN KRUIJSDIJK, C. and OLDENZIEL, T. "Semi-Automatic History Matching Using the Pilot Point Method Including Time-Lapse Seismic Data" SPE 71634 SPE Annual Technical Conference and Exhibition, New Orleans, Louisiana, 30 September–3 October, 2001.
- BRUN, B.; GOSSELIN, O and BARKER, J. W. "Use of Prior Information in Gradient-Based History-Matching" SPE 66353 SPE Reservoir Simulation Symposium, Houston, Texas, 11-14 February 2001.
- CHRISTIE, M. A. and BLUNT, M. J. "Tenth SPE comparative solution project: a comparison of upscaling techniques." SPE 72469, SPE Reservoir Engineering and Evaluation. 4 (4), 308-317, August, 2001.
- MASCHIO, C. e SCHIOZER, D. J. "Ajuste de Histórico Assistido Usando Métodos de Otimização de Busca Direta" IBP06204, Anais do Rio Oil & Gas Conference, Rio de Janeiro, 4-7 de Outubro, 2004.
- MASCHIO, C. and SCHIOZER, D. J. "A new upscaling technique based on Dykstra–Parsons coefficient: evaluation with streamline reservoir simulation." Journal of Petroleum Science and Engineering, vol. 40, pg. 27-36, 2003.
- QUENES, A; and SAAD, N. "A New, Fast Parallel Simulated Annealing Algorithm for Reservoir Characterization" SPE Annual Technical Conference and Exhibition, 3-6 October, Houston, Texas, 1993.
- ROMERO, C. E.; CARTER, J. N.; ZIMMERMAN, R. W. and GRINGARTEN, A. C. "Improved Reservoir Characterization through Evolutionary Computation" SPE Annual Technical Conference and Exhibition, Dallas, Texas, 1-4 October 2000.
- SCHULZE-RIEGERT, R. W.; AXMANN, J. K.; HAASE, O.; RIAN, D. T. and Y. L. YOU, "Optimization Methods for History Matching of Complex Reservoirs", SPE 66393 SPE Reservoir Simulation Symposium, Houston, Texas, 11-14 February 2001.