

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



TÍTULO DO TRABALHO:

UMA NOVA METODOLOGIA PARA MITIGAÇÃO DE INCERTEZAS BASEADA EM DADOS HISTÓRICOS UTILIZANDO TÉCNICAS DE AMOSTRAGEM

AUTORES:

Cássio Pettan Viegas de Carvalho

Denis José Schiozer

Célio Maschio

INSTITUIÇÃO:

Departamento de Engenharia de Petróleo

Faculdade de Engenharia Mecânica

Universidade Estadual de Campinas

Este Trabalho foi preparado para apresentação no 5º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás- 5º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás-ABPG, no período de 15 a 22 de outubro de 2009, em Fortaleza-CE. 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 5ºPDPETRO.

UMA NOVA METODOLOGIA PARA MITIGAÇÃO DE INCERTEZAS BASEADA EM DADOS HISTÓRICOS UTILIZANDO TÉCNICAS DE AMOSTRAGEM

Abstract

Reservoir characterization through uncertainties reduction allows performance prediction with risk mitigation. The main objective of the present work is the development of a methodology that improves the efficiency of reservoir management by adding realistic prediction, considering multiple scenarios in the history matching process. Basically, the idea is to represent the quality of the model by using an objective function that computes the differences between the simulated curve and the historical data and then, based on these assessments, perform changes in the probabilistic distributions of the considered attributes, in order to mitigate uncertainties. This type of procedure was used before but it was not viable with a high number of uncertain attributes; using the Monte Carlo method and a new procedure to calculate the probabilistic redistributions, we have created a methodology that is able to handle high number of parameters, allowing the application to real field examples. The methodology was compared to other similar methods and it presents advantages in terms of the number of required simulations and computational effort. During this project, some challenges must be faced, specially the definition of the method of probabilistic redistribution among the levels of each attribute with a low number of simulations. The development of these procedures must take in to account several factors, as the number of considered attributes and levels, the expected quantity of iterations, the calculated error of each model etc. The methodology was applied to an eight uncertain attributes case to validate the procedure and to show its applicability.

Introdução

A previsão de comportamento é fundamental no desenvolvimento e gerenciamento de reservatórios, possibilitando diversas tomadas de decisões que contribuam para uma produção mais eficiente e com menores riscos. E a utilização do simulador de fluxo é essencial para que este processo se realize, tornando-se uma ferramenta indispensável na indústria petrolífera moderna.

Conjuntamente, a caracterização de reservatórios é uma etapa que auxilia na interface entre estes dois processos citados, pois com uma maior resolução a respeito das propriedades de um campo, a simulação numérica de fluxo se torna muito mais exata e mais confiável. Porém, mesmo com o avanço no processo de caracterização, é necessária a calibração (ajuste de histórico) do modelo de simulação com o objetivo de reproduzir o comportamento passado e tornar a previsão futura mais confiável.

E integrando todos estes aspectos mencionados, encontra-se o processo de redução de incertezas através da integração com o processo de ajuste de histórico, cujo objetivo é mitigar os riscos envolvidos na previsão de comportamento.

Diversos trabalhos e desenvolvimentos foram e ainda são realizados nesta linha de pesquisa, mas os principais projetos que influenciaram na proposta desta metodologia foram os apresentados por Maschio (2005), Moura Filho (2006) e Becerra (2007). Uma abordagem utilizando a árvore de derivação é aplicada por estes autores, alternativa que permite uma solução consolidada para a integração do ajuste de histórico com a análise de incertezas. Porém, a árvore de derivação apresenta limitações devido ao grande número de simulações, sendo adequada a casos com poucos atributos incertos (até no máximo 6 ou 7 atributos, dependendo do caso). O objetivo desse trabalho é propor uma metodologia para contornar a limitação da árvore de derivação e possibilitar a análise de casos com maior número de variáveis.

Metodologia

Um fluxograma representativo da metodologia é ilustrado através da Figura 1. São exibidos todos os passos necessários para que ocorra o processo de redução de incertezas, conferindo assim menores riscos em avaliações de reservatórios.




Figura 1 - Fluxograma da Metodologia Proposta

As principais contribuições do trabalho apresentam-se em duas etapas: “*Seleção do Modelo a ser Avaliado*”, através da técnica de Monte Carlo e a “*Redistribuição das Probabilidades*”, através do algoritmo proposto. Utilizando os novos conceitos aqui apresentados, foi possível a adaptação de um processo já consolidado para redistribuição de probabilidades, apresentado por Moura Filho (2006) e Becerra (2007), de modo a permitir a aplicação do processo de redução de incertezas a casos de maior complexidade.

É válido ressaltar que, durante a etapa de desenvolvimento e calibração da metodologia, utilizou-se um meta-modelo para avaliar a função objetivo. Como descrito por Risso (2007), utilizando planejamento estatístico é possível a criação de superfícies de resposta que representem o comportamento de reservatórios, podendo em certas situações substituir o simulador de fluxo. Portanto, no primeiro momento, a etapa do fluxograma “*Análise do Afastamento (Histórico –*

Simulado)² ” ocorreu através de uma superfície de reposta, tornando muito mais dinâmico o processo de desenvolvimento, já que o tempo requerido por um meta-modelo é bem inferior ao tempo gasto em uma simulação de fluxo, principalmente para casos de maior complexidade.

A metodologia que serviu como base para o desenvolvimento do novo processo proposto neste projeto usa como função objetivo o afastamento entre os dados observados (histórico) e os dados simulados. A partir do resultado desta função, é realizada a redistribuição das probabilidades de ocorrência entre os níveis dos atributos incertos considerados. Esta redistribuição é feita calculando-se primeiramente o somatório dos afastamentos de todos os modelos, da seguinte maneira:

$$K_n = \sum_{j=1}^{Mn} (K_q)_j \quad (1)$$

sendo n o nível em questão, K_q o afastamento entre os dados observados e os simulados do modelo j , e Mn o número de modelos que o nível n participa. O cálculo de K_q é realizado através da equação 2:

$$K_q = \sum_{i=1}^t (d_i^{hist} - d_i^{simulado})^2 \quad (2)$$

onde, d_i é o dado simulado, ou observado, no tempo i , referente a certo modelo e t é o período de avaliação e representa o número de dados observados.

O número de modelos que cada nível n participa é dado através da seguinte equação:

$$Mn = k^{A-1} \quad (3)$$

sendo, A o número de atributos incertos considerados e k o número de níveis deste atributo.

Conhecidos estas variáveis, as novas probabilidades de cada nível podem ser calculadas através da seguinte equação:

$$P_n = \frac{|K_n^{-1}|}{\sum_{n=1}^k |K_n^{-1}|} \quad (4)$$

Pode se perceber a inviabilidade deste processo prévio em casos com muitos atributos incertos, pois para se realizar uma redistribuição é necessário o conhecimento de todos os modelos possíveis. E este requerimento pode não ser atendido em situações onde o esforço computacional necessário torna-se impraticável, já que cada modelo representa uma execução do simulador de fluxo. A Tabela 1 exemplifica brevemente o crescimento da quantidade de modelos em função da quantidade de atributos considerados. As situações exibidas são todas para casos onde cada atributo é discretizado em três níveis.

Número de Atributos Incertos Considerados	Quantidade Total de Modelos
4	81
8	6.561
16	43.046.721

Tabela 1 - Crescimento do Número Total de Modelos

A solução proposta nesta nova metodologia para contornar esta dificuldade é a utilização de estimativas, a partir de uma quantidade suficiente de modelos conhecidos. Mais especificamente, estima-se o valor de cada K_n , que representa a soma dos erros dos modelos que o nível n compõe, permitindo assim a realização das redistribuições. Entende-se por erro do modelo, o afastamento entre seus dados simulados e o histórico, assim como mostrado através da *Equação 2*. Para a realização destas estimativas as seguintes equações foram desenvolvidas, sendo responsáveis por este cálculo:

$$K_n^e = \left[\sum_{j=1}^{p_n} (K_{iq})_j \right] \cdot \left(\frac{Mn}{p} \right) \quad (5)$$

sendo, K_n^e a estimativa da soma, p o número de modelos conhecidos compostos pelo nível n , e K_{iq} o inverso do afastamento de cada modelo, que é dado através da equação abaixo:

$$K_{iq} = (K_q)^{-F} \quad (6)$$

sendo, K_q determinado pela *Equação 2* e F um fator de ponderação.

Este fator de ponderação citado é responsável por valorizar aqueles modelos que apresentem melhores resultados, influenciando de modo com que os níveis que os compõe tenham suas probabilidades realçadas. Para o procedimento, F representa um valor variável na forma de *input* do algoritmo, podendo tornar as redistribuições mais ou menos acentuadas, dependendo dos interesses de aplicação da metodologia.

Calculados estes valores, as novas probabilidades podem ser encontradas. A *Equação 7* é responsável pela determinação destes resultados:

$$P_n = \frac{|K_n^e|}{\sum_{n=1}^k |K_n^e|} \quad (7)$$

Uma consideração relevante é avaliar que a metodologia desenvolve-se de maneira iterativa, incrementando a cada passo o valor de p para um dos níveis incertos de cada atributo. Mas é importante verificar também que o procedimento descrito acima só pode ser aplicado caso $p \geq 1$. Se nenhum dos modelos conhecidos até a iteração presente for composto pelo nível n , é utilizado um processo auxiliar, descrito pelas equações abaixo:

$$K_n^e = Mn \times \sum_{j=1}^p \left[(K_{iq})_j \cdot \frac{y_j}{Y} \right] \quad (8)$$

sendo, p o número total de modelos já conhecidos. Já as variáveis Y e y_j podem ser calculadas através das seguintes equações:

$$Y = \sum_{j=1}^p y_j \quad (9)$$

$$y_j = \left| (n_e) - (n_m)_j \right|^{-1} \quad (10)$$

onde, n_e é a posição (índice na malha) do nível do qual deseja-se estimar a soma, e n_m a posição (também o índice) do nível do modelo j já conhecido.

Sendo conhecidos estes dados, a aplicação da *Equação 7* resulta nas novas probabilidades de cada nível.

Resultados e Discussão

Os resultados foram gerados através da aplicação da metodologia no caso ilustrado através da Figura 2, um reservatório sintético com oito atributos incertos. Neste reservatório, cada região possui um valor incerto de permeabilidade absoluta na direção horizontal. Através destas condições, escolheu-se aleatoriamente um modelo para se gerar o histórico sintético, que é utilizado como modelo de referência nesta aplicação.




Figura 2 - Reservatório utilizado

Foram utilizadas 100 iterações na redistribuição das probabilidades, com um fator de ponderação $F = 2.5$. Além disso, para todos os atributos incertos foi considerada uma distribuição inicial de probabilidades uniforme entre os níveis. Cada um dos oito atributos foi discretizado em três níveis de incerteza, com seus respectivos valores iguais a: 1000, 4500 e 7500 mD.

Os perfis de probabilidades obtidos após a utilização da metodologia são mostrados através da Figura 3 para cada um dos oito atributos considerados.




Figura 3 - Distribuições de Probabilidades Posteriores à Aplicação da Metodologia

Nesta figura, é exibida uma marcação na cor *vermelha* em cada um dos atributos ilustrados, representando o sentido esperado da convergência, ou seja, a localização do valor correto da permeabilidade de cada uma das regiões do reservatório. Entende-se por valor correto aquele que foi utilizado para gerar o histórico sintético e, que, na *Equação 2*, auxilia na composição da função objetivo. Portanto é esperado que os níveis de maiores probabilidades sejam aqueles que abranjam o valor real, ou seja, as marcações *vermelhas* na Figura 3. Estes valores reais, que compõe o modelo gerador do histórico, são exibidos na *Tabela 2*.

Atributos	1	2	3	4	5	6	7	8
Permeabilidade Real [mD]	6257	4663	2256	1008	4803	4119	3277	6824

Tabela 2 - Valores Reais de Cada Atributo

Através destes novos perfis pode ser traçada a nova curva de incerteza, que é exibida através da Figura 4. A curva em *vermelho* refere-se à distribuição inicial de probabilidades. Já a curva em *azul* é proveniente das novas distribuições de probabilidades, obtidas com a metodologia.





Figura 4 - Comparação entre a Curva de Incertezas Inicial e a Obtida Através da Metodologia

Pode-se observar nesta figura que a nova curva de incertezas apresentou uma configuração assim como era esperada. Essa inclinação mais acentuada na região central, apresentada pela curva obtida, demonstra que os modelos de menores afastamentos possuem maiores probabilidades de ocorrência.

A partir das curvas de incerteza, foram selecionados os modelos representativos dos percentis P10 e P90. As curvas de produção de alguns dos poços são exibidas nas Figuras 5 e 6, juntamente com a curva de produção acumulada de água (campo). As linhas em *vermelho* para estes gráficos representam as curvas P10 e P90 para a situação da distribuição inicial, enquanto as linhas em *azul* representam as curvas P10 e P90 para a situação posterior à aplicação da metodologia.



Figuras 5- Curvas P10 e P90 antes e depois da aplicação da metodologia para o poço 1 (a) e 4 (b)




Figura 6 – Curvas P10 e P90 antes e depois da aplicação da metodologia para o poço 6 (a) e campo (b)

Nestas curvas, pode-se observar a tendência da redução do envelope entre P10 e P90 após a aplicação da metodologia. Isto representa menores incertezas nos perfis produção, o que remete a uma previsão de menores riscos.

Conclusões

Através dos resultados pôde-se observar uma boa convergência do método proposto. Além disso, nesta aplicação, um número reduzido de iterações foi utilizado. A técnica da árvore de derivação exigiria para este caso um total de 6561 simulações para que as probabilidades fossem redistribuídas, enquanto a aplicação aqui realizada gerou novos perfis probabilísticos com apenas 100 simulações. Portanto é notável a redução do esforço computacional alcançada por esta nova metodologia, minimizando o tempo demandado nesta fase de caracterização e avaliação. Essa diminuição no esforço computacional abre novas frentes de pesquisa para o método de redução de incertezas, pois possibilita o aumento no número de atributos a serem ajustados, incluindo atributos para ajuste local em poços, o que será investigado na continuação nesta linha de pesquisa.

Agradecimentos

O autor gostaria de agradecer seus orientadores, Petrobras (SIGER), CEPETRO, PRH-ANP, FINEP, UNISIM e DEP por fornecer condições e apoio para a realização deste trabalho.

Referências Bibliográficas

BECERRA, G.G. “Mitigação de Incertezas através da Integração com Ajuste de Histórico de Produção”. Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, 2007. 192pp. Dissertação (Mestrado).

MASCHIO, C., SCHIOZER, D. J. e MOURA FILHO, M. A. B. “A Methodology to Quantify the Impact of Uncertainties in the History Matching Process and in the Production Forecast”, SPE 96613, Annual Technical Conference and Exhibition, Dallas, Texas, 9-12 Outubro 2005.

MOURA FILHO, M. A. B. “Integração de Análise de Incertezas e Ajuste de Histórico de Produção”. Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, 2006. 150pp. Dissertação (Mestrado)

RISSO, V. F., SCHIOZER, D. J., “Ajuste de Histórico Utilizando Planejamento Estatístico e Combinação de Dados de Produção, Pressão e Mapas de Saturação”. Campinas. Faculdade de Engenharia Mecânica, Departamento de Engenharia de Petróleo, Unicamp, 2007. Tese (Doutorado).