

“As variáveis de otimização são os parâmetros das distribuições de probabilidade.”

Interesses especiais:

- [UNISIM](#)
- [Publicações UNISIM](#)
- [Portal de Simulação de Gerenciamento de Reservatórios](#)
- [UNIPAR](#)
- [Edições anteriores](#)

Links:

- [Unicamp](#)
- [Cepetro](#)
- [Dep. Eng. Petróleo](#)
- [Fac. Eng. Mecânica](#)
- [Ciências e Eng. de Petróleo](#)

Pós-Graduação:

Ciências e Engenharia de Petróleo: interessados em Mestrado e Doutorado na área de Simulação e Gerenciamento de Reservatórios de Petróleo [cliquem aqui](#).

Procedimento de Otimização para Integração entre Ajuste de Histórico e Redução de Incertezas

Célio Maschio

1. Introdução

Em um processo de otimização convencional aplicado ao problema de ajuste de histórico, o objetivo é encontrar as melhores combinações dos valores dos atributos do reservatório, tais como porosidade e permeabilidade, por exemplo, de forma a minimizar a diferença entre os dados simulados e observados. O objetivo é encontrar uma ou mais soluções do tipo $x = [x_1, x_2, \dots, x_n]$, onde x representa os valores dos n atributos incertos.

O objetivo deste trabalho é propor um procedimento de otimização, baseado em algoritmo genético e redes neurais artificiais, no qual as variáveis de entrada do processo de otimização são os parâmetros da distribuição de probabilidade de cada atributo incerto. A ideia é reduzir a incerteza dos atributos e, como consequência, reduzir a incerteza na previsão, no sentido de integrar as abordagens 3 e 4 apontadas por [Schiozer \(2013\)](#).

2. Metodologia

A metodologia proposta consiste das seguintes etapas:

- 1) Amostragem inicial: sorteio de um número de amostras a partir das distribuições *a priori* para treinamento das redes neurais;
- 2) Treinamento das redes neurais: as amostras geradas na Etapa 1 são utilizadas para treinar as redes neurais e gerar as *proxies*;
- 3) Otimização: no processo de otimização proposto, cujo fluxograma está mostrado na Fig. 1-a, o objetivo é encontrar uma combinação de parâmetros (média e desvio-padrão, por exemplo) da distribuição de probabilidade de cada atributo incerto. No processo convencional, cada vetor do tipo x gera uma simulação. Já no método proposto, cada vetor y gera m simulações, sendo m o número de amostras (conjunto de vetores x) geradas a partir das distribuições de cada atributo (Fig. 1-b). A solução, portanto, é um vetor do tipo $y = [\mu_{x1}, \sigma_{x1}, \mu_{x2}, \sigma_{x2}, \dots, \mu_{xn}, \sigma_{xn}]$ que minimiza a dispersão das curvas em torno do histórico (Fig. 1-c), sendo μ e σ parâmetros das distribuições de probabilidade dos atributos do reservatório. A função objetivo, FO (y), é composta pelos afastamentos das m simulações. Portanto, cada combinação de parâmetros (vetor y) gera uma família de simulações, ao invés de uma, como ocorre no processo de otimização convencional.
- 4) Avaliação dos resultados: após a etapa de otimização, um conjunto final de amostras é gerado a partir das distribuições finais e avaliado com o simulador de escoamento.

3. Aplicação e Resultados

A metodologia foi aplicada ao modelo de reservatório mostrado na Fig. 2, o qual é composto por três facies de acordo com três faixas de

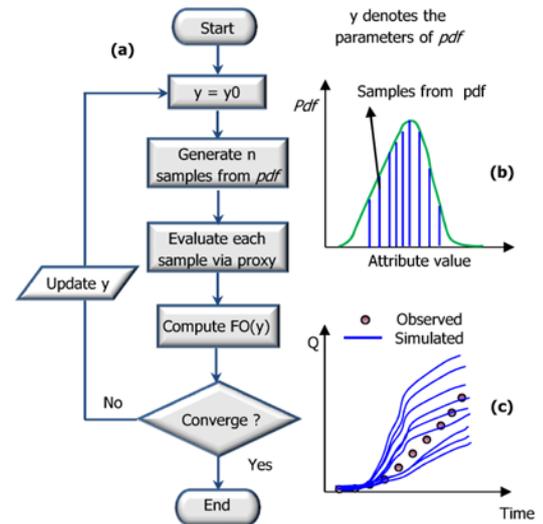


Figura 1: Processo de otimização proposto (adaptada de Maschio e Schiozer, 2014).

permeabilidade (baixa, média e alta). Em cada facie são considerados 3 multiplicadores de porosidade, 3 de multiplicadores do logaritmo da permeabilidade, 3 de k_z , 4 multiplicadores de transmissibilidade de falhas e 3 expoentes de Corey (fase água), totalizando 16 atributos incertos. Uma combinação dos 16 atributos foi escolhida ao acaso para ser utilizada como modelo referência. A estratégia de produção é composta por 8 poços produtores e 7 injetores de água, todos verticais.

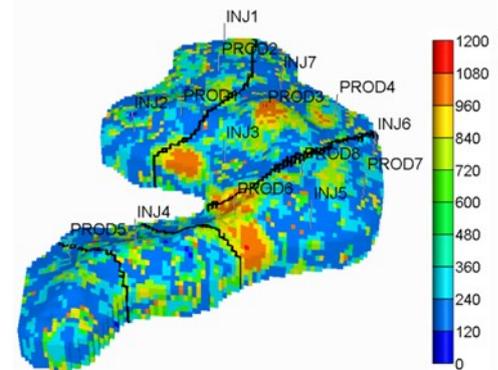


Figura 2: Permeabilidade horizontal do modelo estudado (mD).

Utilizando a técnica de Hipercubo Latino, foram geradas 200 amostras para o treinamento das redes neurais, o qual foi realizado utilizando a *toolbox* de redes neurais do MatLab. Foram treinadas 8 redes para representar a vazão de água de cada um dos 8 poços produtores.

A Figura 3 mostra uma comparação entre as curvas de vazão de água de um poço geradas pela *proxy* e pelo simulador, na qual é possível observar uma boa concordância entre os resultados. O cálculo de FO(y) é feito com os resultados obtidos com as *proxies*.

Para a otimização, foi utilizado o algoritmo genético disponível no MatLab. Foram definidas 30 gerações com 100 indivíduos. Durante a oti-

“O procedimento proposto permite a redução de incertezas dos atributos do reservatório e, como consequência, a redução de incertezas na previsão de produção.”

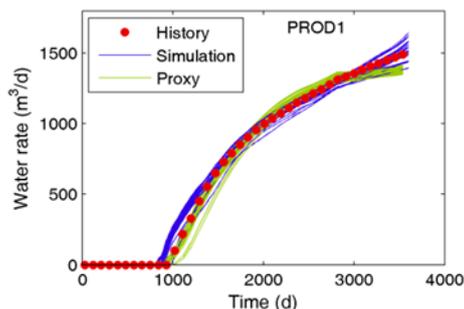


Figura 3: Comparação entre o resultado da proxy e do simulador.

mização, foram geradas para cada indivíduo 50 amostras por meio do Hipercubo Latino, totalizando 150000 avaliações da FO.

A Figura 4 mostra, para um dos atributos, a distribuição *a priori* (considerada uniforme nesse estudo), a distribuição *a posteriori*, resultante do processo de otimização, bem como o valor de referência. Pode-se observar que o pico de maior densidade de probabilidade (moda da distribuição) ocorre bem próximo do valor de referência. Seguindo a Etapa 4 da metodologia, a distribuição final foi utilizada para gerar um conjunto final de 100 amostras as quais foram utilizadas para realizar a previsão de produção, usando o simulador de escoamento.

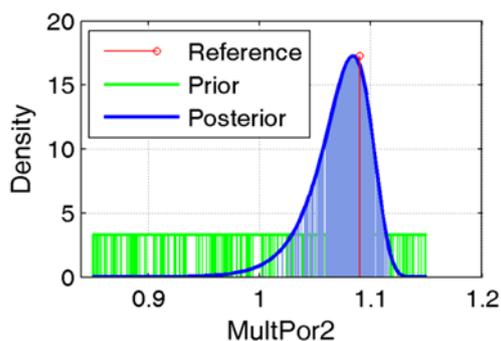


Figura 4: Valor de referência, distribuição *a priori* e distribuição *a posteriori* para um dos atributos.

A Figura 5 mostra a produção acumulada de óleo para um dos poços. O conjunto de curvas pretas foi gerado com os 100 modelos sorteados da distribuição final e o conjunto de curvas cinza foi gerado a partir da distribuição *a priori*, para efeito de comparação da dispersão de curvas antes e após a aplicação da metodologia. Pode-se observar uma redução significativa na dispersão das curvas. A redução de incerteza na produção acumulada de óleo foi de 71% (média dos 8 poços produtores) e de 63,5% para produção acumulada de água.

Mais detalhes deste trabalho estão em Maschio e Schiozer (2014).

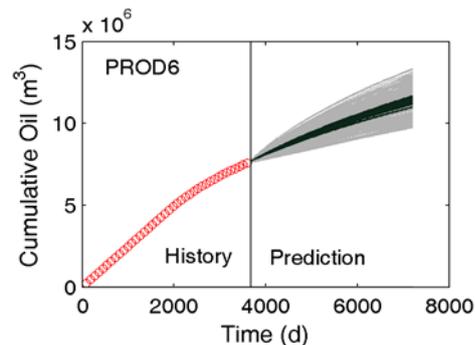


Figura 5: Comparação da previsão de produção antes e após a aplicação da metodologia.

4. Considerações Finais

Neste trabalho foi apresentado um novo procedimento de otimização o qual permite a redução de incertezas dos atributos do reservatório e, como consequência, permite reduzir incertezas na previsão de produção. Para o caso testado, a aplicação de algoritmo genético combinado com redes neurais foi feita com sucesso, gerando bons resultados com baixo esforço computacional.

Uma limitação do método proposto, que na verdade é inerente a qualquer método que usa proxy para substituir o simulador de escoamento, é a dificuldade em trabalhar com atributos discretos, tais como imagens geradas por geoestatística, tabelas de permeabilidade relativa, tabelas PVT, dentre outros. Para esses casos, outros métodos para geração de proxy devem ser pesquisados. Sugere-se também para pesquisas futuras a aplicação do método em casos mais complexos.

Outras abordagens estão sendo estudadas no UNISIM, dentre elas, a aplicação de MCMC no contexto de inferência Bayesiana, pelo qual uma das vantagens é a obtenção de amostras da distribuição *a posteriori* conjunta. Resultados dessa abordagem serão apresentados em edições futuras do UNISIM ON-LINE.

5. Referências

Schiozer, D. J. “Ajuste de Histórico de Produção e Redução de Incertezas; Alguns Conceitos”, UNISIM ON-LINE, Publicação do Grupo UNISIM, Ano 8, Volume 6, 74ª Edição, Setembro de 2013.

Maschio, C.; Schiozer, D. J., “A New Optimization Framework Using Genetic Algorithm and Artificial Neural Network to Reduce Uncertainties in Petroleum Reservoir Models”, *Engineering Optimization*, v. 46, pp. 1-13, January, 2014. <http://www.tandfonline.com/loi/geno20>

Informações sobre o autor:

Célio Maschio é engenheiro mecânico pela Unesp, mestre e doutor em Engenharia Mecânica pela UNICAMP e pesquisador do UNISIM.

Oportunidades no UNISIM:

Se você tem interesse em trabalhar ou desenvolver pesquisas no UNISIM, entre em contato conosco. Interesse imediato em:

- Pesquisador na área de simulação, gerenciamento e caracterização de reservatórios.

Para mais detalhes, [clique aqui](#).



Grupo de Pesquisa em Simulação e Gerenciamento de Reservatórios

Dep. Eng. Petróleo
Fac. Eng. Mecânica
Centro de Estudos de Petróleo
Univ. Estadual de Campinas
Campinas - SP

Tel.: 55-19-3521-1220
Fax: 55-19-3289-4916

unisim@dep.fem.unicamp.br

Para maiores informações, visite

<https://www.unisim.cepetro.unicamp.br>

O UNISIM é um grupo de pesquisa da UNICAMP (Departamento de Engenharia de Petróleo, Faculdade de Engenharia Mecânica, Centro de Estudos de Petróleo - CEPETRO) que tem como objetivo desenvolver trabalhos e projetos na área de simulação e gerenciamento de reservatórios.