

---

# Aplicando Ensemble Kalman Filter ao Ajuste de Histórico de Pressão em Lobos Turbidíticos<sup>1</sup>

Thiago M. D. Silva<sup>2</sup> Abelardo Barreto<sup>3</sup> Sinesio Pesco<sup>4</sup>  
PUC-Rio, Departamento de Matemática

**Resumo.** Lobos turbidíticos são elementos arquiteturais responsáveis pela formação de um importante reservatório de petróleo. Neste trabalho propomos uma caracterização petrofísica de um modelo baseado em objetos de lobos turbidíticos a partir de um ajuste de histórico de dados de pressão observadas durante um teste de poço com duração de 4 dias. Para tal, foi utilizado o método de assimilação de dados Ensemble Kalman Filter.

**Palavras-chave.** Ensemble Kalman Filter, Ajuste de Histórico, Lobos Turbidíticos, Teste de Poço, Simulação de Reservatórios.

## 1 Introdução

Um dos grandes desafios para a indústria de petróleo é a diminuição das incertezas referentes a uma possível exploração de hidrocarbonetos. A busca por um modelo geométrico que represente o reservatório começa desde os primeiros dados adquiridos antes da produção, como sísmica e geologia do ambiente, e vai sendo atualizado a medida que novos dados são observados. O modelo é atualizado a fim de tentar prever, através de simuladores, como o reservatório original se comportaria com a aplicação de métodos de recuperação de óleo e gás.

Um dos métodos de caracterização de reservatórios, estudado amplamente ao percorrer dos anos, é o ajuste de histórico automático, onde a produção de hidrocarboneto já vem sendo feita durante um período, juntamente com a observação de dados, e busca-se aprimorar o modelo construído, a partir da atualização de seus parâmetros, com objetivo de obter dados simulados similares ao histórico de dados observados. Nesta técnica, além do modelo geométrico de reservatório, precisamos de um algoritmo de otimização para estimar tais parâmetros para o modelo. Dentre os diversos métodos aplicados no problema de ajuste de histórico na área de óleo e gás, podemos citar os *baseados no gradiente*, como Gauss-Newton [4], Levenberg-Marquardt [1] e BFGS [3]. Contudo, recentes pesquisas têm voltado sua atenção para os métodos baseados no *Filtro de Kalman (KF)*,

---

<sup>1</sup>Este trabalho foi parcialmente financiado pela Petrobras e Capes.

<sup>2</sup>thiagomenez@gmail.com

<sup>3</sup>abelardo.puc@gmail.com

<sup>4</sup>sinesio@puc-rio.br

um filtro recursivo que estima o estado de um sistema linear por meio de uma série de aproximações [5].

O método de assimilação de dados *Ensemble Kalman Filter* (EnKF) [2] é uma implementação de Monte Carlo baseado no KF, onde a média de um conjunto de realizações oferece uma boa estimativa para o modelo a ser caracterizado. O EnKF evita algumas das principais limitações do KF, por exemplo, não é preciso linearizar o modelo dinâmico adotado ou as relações entre as variáveis de estado e os dados [9]. Foi introduzido por Evensen [2] e possui diversas aplicações, tais como ciências econômicas, geofísica, estatística e, mais notoriamente, meteorologia. Sua primeira aplicação na área de petróleo se deu em 2001, por Lorentzen [7]. Logo após, Naevdal *et al.* [8] publicou um estudo utilizando EnKF para atualização das permeabilidades dos modelos de reservatórios, a partir de um monitoramento de uma região no entorno de um poço, objetivando prever dados de produção consistentes com dados históricos, sendo o primeiro trabalho aplicando EnKF ao ajuste de histórico com simulação de reservatórios. Liu e Oliver [6] examinaram o EnKF na estimação de facies em modelos de reservatórios, o que é um problema altamente não linear, onde o reservatório é composto por areia e argila, com diferentes porosidades e permeabilidades. Zafari e Reynolds [14] usaram modelos não lineares para testar a validade do esquema de atualização linear usado no EnKF. Com o passar dos anos, diversos estudos têm sido publicados. Na Figura 1 vemos o número de publicações sobre EnKF no *Science Direct* [11] e *OnePetro* [10] desde o ano 2000 até 2018.

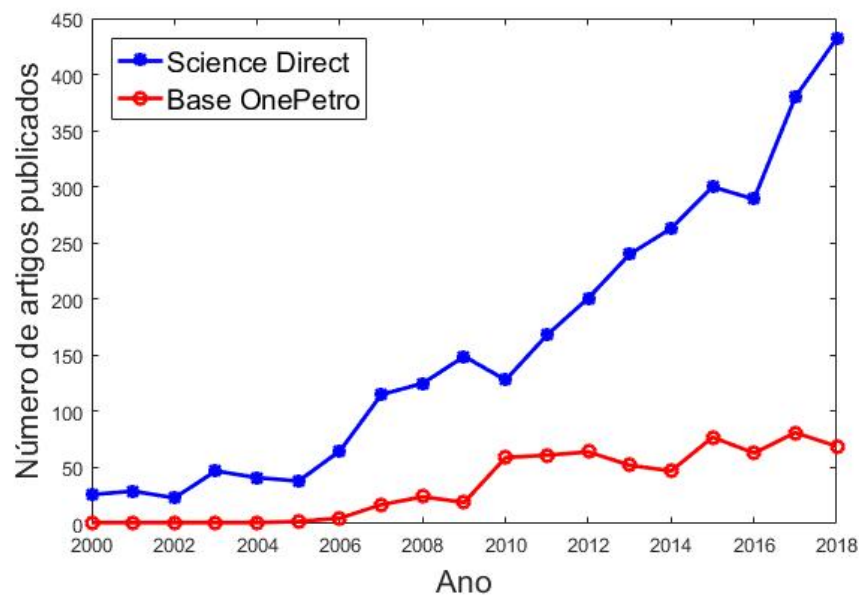


Figura 1: Número de artigos sobre EnKF [10,11]

Para mais informações sobre o EnKF aplicado a ajuste de histórico de simulação e caracterização de reservatórios, ver [9].

## 2 Ensemble Kalman Filter (EnKF)

Para a implementação do EnKF, todas as variáveis de interesse são coletadas e alocadas em um vetor de estado  $y$ . Usualmente  $y$  é formado por porosidade  $\phi$ , permeabilidade  $k$ , dados de pressão  $p$ , saturação de água  $S_w$  e vazão de água  $q_w$  e óleo  $q_o$ .

$$y = [\phi, k, p, S_w, q_w, q_o]^T \quad (1)$$

Um conjunto de vetores de estado são coletados em uma matriz  $Y$  consistentes com conhecimentos prévios do estado inicial

$$Y = [y_1, y_2, \dots, y_{N_e}] \quad (2)$$

onde  $N_e$  é o número total de membros do conjunto  $Y$  e  $y_j, j \in \{1, \dots, N_e\}$  são vetores de estado. Como no Kalman Filter usual, EnKF consiste em dois estágios sequenciais: (i) a previsão adiante em relação ao tempo, baseada na solução das equações de dinâmica para escoamento e transporte no reservatório e (ii) análise ou assimilação de dados, onde as variáveis que caracterizam o estado do sistema são atualizadas de acordo com os dados observados. Para o primeiro passo (i) são gerados  $N_e$  amostras independentes  $m_0^j, j \in \{1, \dots, N_e\}$ , modelos do sistema e, então, gerar  $g(m_0^j)$ , onde  $g$  é o simulador. Para cada  $j$  é criado um vetor de estado  $y_j = [m_0^j, g(m_0^j)]^T$ . No segundo passo (ii), cada membro do conjunto  $Y$  é atualizado usando uma aproximação por conjunto da fórmula de ganho de Kalman [2, 5]:

$$y_j^a = y_j^f + K_e(d_j - Hy_j^f), \text{ para } j \in \{1, \dots, N_e\} \quad (3)$$

onde  $K_e$  é a matriz de ganho de Kalman por conjunto e  $H$  é a matriz que extrai de  $y_j$  os dados simulados:

$$H = [ 0 \quad I ]$$

$d_j$  é o vetor de dados observados perturbado por  $\epsilon_j \approx \mathcal{N}(0, C_D)$ , onde  $C_D$  é a matriz de covariância dos erros de medição dos dados observados.

$$d_j = d_{obs} + \epsilon_j, \quad j \in \{1, \dots, N_e\}$$

A matriz de ganho de Kalman é definida por

$$K_e = C_Y H^T (H C_Y H^T + C_D)^{-1}$$

$$C_Y = \frac{1}{N_e - 1} \sum_{j=1}^{N_e} (y_j - \bar{y})^T (y_j - \bar{y})$$

$\bar{y}$  é a média de todos  $N_e$  membros  $y_j$  do conjunto  $Y$ .

### 3 Resultados

Nesta seção apresentaremos o modelo de reservatório utilizado neste trabalho e, em seguida, os resultados obtidos com a aplicação do EnKF no ajuste de histórico de pressão.

#### 3.1 Modelo de Lobo Turbidítico

Neste trabalho utilizamos um modelo baseado em objetos de lobo turbidítico com três camadas utilizando curvas B-Spline univaloradas, apresentado em [12]. O formato do reservatório é definido por uma superfície de base representando o cânion da Baía de Monterey, Califórnia, EUA. A Figura 2 apresenta o modelo utilizado como referência para otimização neste trabalho.




Figura 2: Modelo baseado em objetos de lobo turbidítico utilizado neste trabalho [12].

#### 3.2 Resultados

Para a implementação do método EnKF, utilizaremos dados de permeabilidade de cada camada. Sendo assim, geraremos  $N_e$  modelos de permeabilidades  $m_0^j = [K_1^{j,0}, K_2^{j,0}, K_3^{j,0}]$ ,

onde  $K_m$  se refere a permeabilidade da camada  $m$ . Em seguida obtemos  $N_e$  vetores de estado  $y_j$  com dados simulados de pressão obtidos através de um simulador comercial. O passo seguinte é atualizar todos os vetores  $y_j$   $j \in \{1, \dots, N_e\}$ , utilizando a fórmula (3). Exibimos na Figura 3 o resultado do ajuste de histórico usando o método EnKF. O parâmetro utilizado no ajuste foi permeabilidade  $k$  e o tamanho do conjunto foi  $N_e = 50$ . No gráfico são mostradas as todas as curvas de pressão componentes do conjunto  $Y$  em linhas de cor ciano, a média do conjunto como bolas azuis e os dados de referência em asterisco vermelho.

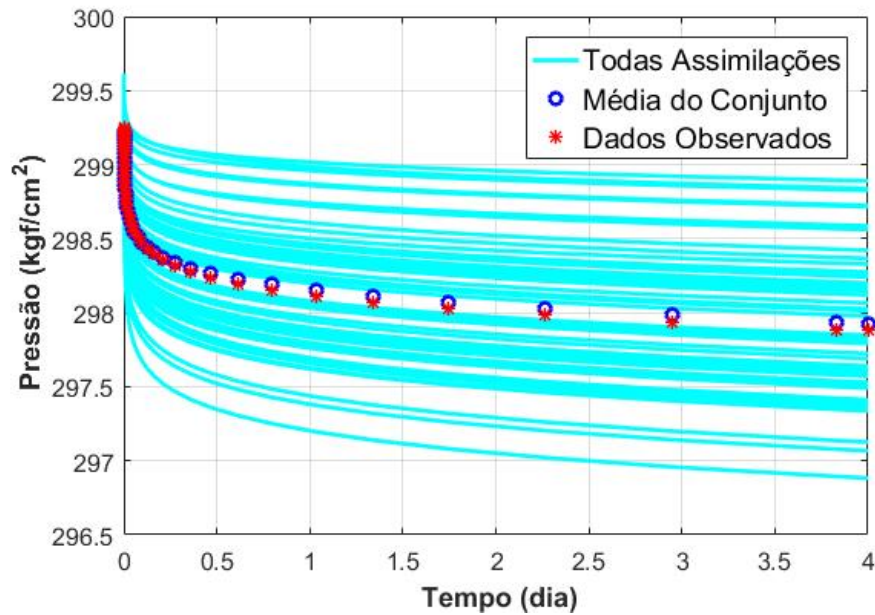


Figura 3: Resultado da aplicação do EnKF.

A Figura 4 exibe o conjunto de permeabilidades encontradas pelo método EnKF para cada camada. Todas as assimilações estão exibidas em cor ciano, a média do conjunto em cor azul e o caso de referência como vermelho.

O problema apresentado neste trabalho é chamado de *problema inverso*, que é altamente não linear [13], não garantindo solução única (temos  $N_e \times N_t$  incógnitas para  $N_t$  observações, onde  $N_t$  é o número de discretizações do tempo em que os valores de pressão são medidos, neste trabalho,  $N_t = 50$ ). Podemos encontrar diferentes combinações de permeabilidades por camada que resultam em dados de pressão similares. Esta disparidade fica evidente na Figura 4, onde as permeabilidades de referência não são honradas, porém, ao analisar a Figura 3, vemos que os dados de pressão simulados possuem grande similaridade com os dados observados. Defina a função objetivo

$$f_{obj} = \sum_{i=1}^{N_t} \left( \frac{p_{ref}^i - p_{sim}^i}{p_{ref}^i} \right) \quad (4)$$

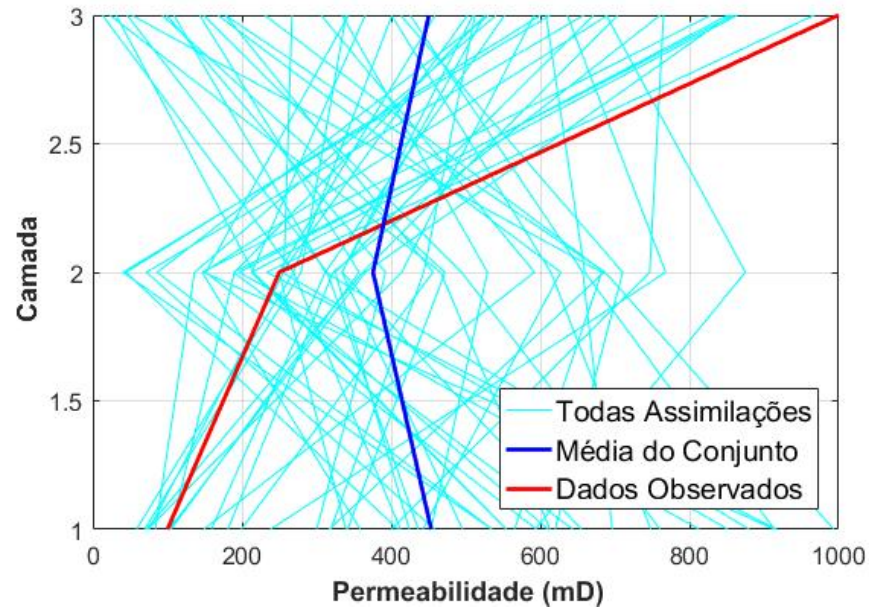


Figura 4: Permeabilidades por camada do conjunto.

onde  $p_{ref}^i$  é a pressão de referência (dado observado) medida no tempo  $t_i$ ,  $i = 1, \dots, N_t$ , e  $p_{sim}^i$  é a pressão simulada (dado simulado) medida no tempo  $t_i$ . Comparando os dados observados com a média das assimilações, utilizando (4), obtemos  $f_{obj} = 7.9018 \times 10^{-06}$ , atingindo um baixo valor de erro, apresentando, então, uma boa aproximação de permeabilidades para o modelo.

## 4 Conclusão

Neste trabalho apresentamos uma aplicação do método Ensemble Kalman Filter no ajuste de histórico de pressão utilizando um modelo de Lobo Turbidítico com 3 camadas apresentado em [12]. Para isto, foi utilizado um conjunto com tamanho 50 e buscamos estimar a permeabilidade de cada camada do sistema. Os dados observados de pressão foram colhidos em um teste de poço simulado com duração de 4 dias e definidos como referência. Na Figura 3 podemos ver como o método obteve um conjunto de permeabilidades de forma que o sistema respondesse dados simulados em um teste de poço similares aos definidos como referência. Porém, analisando a Figura 4, vemos que as permeabilidades não foram aproximadas por camadas. Por outro lado, a permeabilidade equivalente do sistema foi aproximada. Isto se deve ao fato do problema ser não linear, possuindo mais incógnitas a serem resolvidas do que dados observados. Isto garante a possibilidade de existência de múltiplas soluções.

## Referências

- [1] Shirangi, M. G., Emerick, A. A. An improved TSVD-based Levenberg–Marquardt algorithm for history matching and comparison with Gauss–Newton. *Journal of Petroleum Science and Engineering*, 143, 258-271, 2016.
- [2] Evensen, G. The Ensemble Kalman Filter: theoretical formulation and practical implementation. *Ocean Dynamics* 53, 343–367, 2003.
- [3] Gao, G. e Reynolds, A. C. An Improved Implementation of the LBFGS Algorithm for Automatic History Matching. *SPE Journal*, 11, 01, 2006.
- [4] Gao, G., Jiang, H., Hagen, P. V., Vink, J. C., Wells, T. A Gauss–Newton Trust Region Solver for Large Scale History Matching Problems. *SPE Reservoir Simulation Conference*, 20-22 February, Montgomery, Texas, USA, 2017.
- [5] Kalman, R. E. A New Approach to Linear Filtering and Prediction Problems. *J. Basic. Emg*, 82, 35-45, 1960.
- [6] Liu, N. e Oliver, D. S. Ensemble Kalman Filter For Automatic History Matching of Geologic Facies. *Journal of Petroleum Science and Engineering*, 47, 147-161, 2005.
- [7] Lorentzen, R. J., Fjelde, K. K., Froyen, J., Lage, A. C. V. M., Naevdal, G., Vefring, E. H. Underbalance and Low-Head Drilling Operations: Real Time Interpretation on Measured Data and Operational Support. *SPE Annual Technical Conference and Exhibition*, 30 September-3 October, New Orleans, Louisiana, 2001.
- [8] Naevdal, G., Mannseth, T., Vefring, E. H. Near-Well Reservoir Monitoring Through Ensemble Kalman Filter. *SPE/DOE Improved Oil Recovery Symposium*, 13-17 April, Tulsa, Oklahoma, 2002.
- [9] Oliver, D. S., Liu, N., Reynolds, A. C. *Inverse Theory for Petroleum Reservoir Characterization and History Matching*. Cambridge, 2008.
- [10] OnePetro. Disponível em: <https://www.onepetro.org>. Acessado em 13/03/2019.
- [11] Science Direct. Disponível em: <https://www.sciencedirect.com>. Acessado em 13/03/2019.
- [12] Silva, T. M. D. Modelagem Assistida de Lobos Turbidíticos Baseada em Dados de Testes de Formação. *Dissertação de Mestrado*. Pontifícia Universidade Católica do Rio de Janeiro, 2017.
- [13] Tarantola, A. *Inverse Problem Theory and Methods for Model Parameter Estimation*. Siam, 2005.
- [14] Zafari, M. e Reynolds, A. Assessing the Uncertainty in Reservoir Description and Performance Predictions with the Ensemble Kalman Filter. *SPE Annual Technical Conference and Exhibition*, 9-12 October, Dallas, Texas, 2005.