



# IBP1722\_18 ANÁLISE DA INFLUÊNCIA DO TAMANHO DO CONJUNTO NA APLICAÇÃO DO CONJUNTO SUAVIZADO NO PROCESSO DE AJUSTE DE HISTÓRICO

Paulo H. Ranazzi<sup>1</sup>, Marcio A. Sampaio<sup>2</sup>

**Copyright 2018, Instituto Brasileiro de Petróleo, Gás e Biocombustíveis - IBP**

Este Trabalho Técnico foi preparado para apresentação na Rio Oil&Gas Expo and Conference 2018, realizada no período de 24 a 27 de setembro de 2018, na cidade do Rio de Janeiro. Este Trabalho Técnico foi selecionado para apresentação pelo Comitê Técnico do evento, seguindo as informações contidas no trabalho completo submetido pelo(s) autor(es). Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões do Instituto Brasileiro de Petróleo, Gás e Biocombustíveis, Sócios e Representantes. É de conhecimento e aprovação do(s) autor(es) que este Trabalho Técnico seja publicado nos Anais da Rio Oil&Gas Expo and Conference 2018.

---

## Resumo

Em engenharia de reservatórios, o termo ajuste de histórico é o ato de condicionar um modelo de simulação com base nos dados observados disponíveis. Os parâmetros utilizados na construção do modelo de simulação possuem incertezas associadas e, devido a isto, ocorre uma discrepância entre a produção prevista pelo modelo de simulação e os valores observados. Neste artigo, uma metodologia de ajuste baseado em um conjunto de modelos foi utilizada para a realização do ajuste de histórico, de tal forma que seja possível analisar a influência do tamanho deste conjunto nos resultados obtidos. Um eficiente filtro que se tornou popular nos processos de ajuste de histórico é o Conjunto Suavizado com Múltipla Assimilação de Dados (ES-MDA). A influência do tamanho do conjunto foi verificada aplicando o ES-MDA em um modelo de campo sintético, o UNISIM-I-H. Como resultado da aplicação da metodologia, foi possível analisar a qualidade do ajuste dos dados observados, assim como a quantificação das incertezas dos modelos à posteriori em relação ao tamanho do conjunto utilizado no ajuste.

**Palavras-chave:** Simulação de Reservatórios, Ajuste de Histórico, Quantificação de Incertezas.

## Abstract

In reservoir engineering, the act of conditioning a simulation model based on the available data is called history matching. The properties used in the construction of the simulation model have uncertainties, and due to this, a discrepancy occurs between the reservoir forecast and the observed data. In this article, an ensemble-based methodology was used to perform the history matching, in such a way that it is possible to analyze the influence of the ensemble size on the results obtained. An efficient filter that became popular in the history matching procedure is the Ensemble Smoother with Multiple Data Assimilation (ES-MDA). The influence of the ensemble size was analyzed applying the ES-MDA in a synthetic field model, the UNISIM-I-H. As a result of the application of the methodology, it was possible to analyze the matching quality of the observed data, as well as the uncertainty quantification of the posterior models in relation to the size of the ensemble used in the matching.

**Keywords:** Reservoir Simulation, History Matching, Uncertainty Quantification.

<sup>1</sup>Engenheiro de Petróleo, Departamento de Engenharia de Minas e de Petróleo—Universidade de São Paulo

<sup>2</sup>Professor Doutor, Departamento de Engenharia de Minas e de Petróleo—Universidade de São Paulo

## 1. Introdução

O processo de ajuste de histórico é o ato de condicionar um modelo numérico de simulação que tem como objetivo prever o comportamento de um reservatório de petróleo, de acordo com os dados de produção disponíveis. Este modelo é representado a partir de suas respectivas propriedades, porém, muitos dados do reservatório que deverão ser utilizados no modelo de simulação possuem imprecisões envolvidas, principalmente os dados obtidos através de medições indiretas, resultando em incertezas nas propriedades do reservatório. Devido a estas incertezas associadas, ocorre uma discrepância entre a produção prevista pela simulação e a observada no campo. Ao reduzir esta discrepância entre os dados obtidos como resposta do modelo de simulação e os dados observados (medidos diretamente no campo), é obtida uma maior confiabilidade no modelo de simulação, permitindo uma melhor previsão do comportamento futuro do reservatório. O procedimento de ajuste de histórico é justamente promover a revisão do modelo de simulação, reavaliando as propriedades que possuem incertezas associadas, com o objetivo de verificar as condições que são capazes de melhor aproximar as curvas de produção simuladas e observadas. O ajuste de histórico é considerado um problema inverso de múltiplas respostas, ou seja, o mesmo histórico de produção pode ser ajustado utilizando diferentes combinações dos parâmetros incertos do modelo. O fato de o problema possuir múltiplas respostas reforça a necessidade de quantificação de incertezas, de tal forma que seja possível avaliar o impacto destes múltiplos cenários ajustados na previsão do comportamento do reservatório. Desta forma, o ajuste de histórico também pode ser tratado como um problema de inferência bayesiana. Neste contexto, foi desenvolvido o Filtro de Kalman por Conjunto (do inglês, *Ensemble Kalman Filter* – EnKF) (Evensen, 1994; 2003), onde os parâmetros incertos são tratados como variáveis aleatórias e um conjunto de modelos é utilizado para representar os dois primeiros momentos estatísticos. Então, o conjunto é atualizado recursivamente nos períodos em que existirem medições disponíveis. Um dos grandes problemas em relação ao EnKF é a necessidade de atualizar os parâmetros dinâmicos do modelo (pressão e saturação, por exemplo) em cada etapa de assimilação. Devido a isto, uma metodologia que vem sendo empregada com maior frequência no problema de ajuste de histórico é o Conjunto Suavizado (do inglês, *Ensemble Smoother* – ES) (van Leeuwen e Evensen, 1996), onde apenas os parâmetros de entrada do modelo são assimilados e apenas uma etapa de assimilação com todos dados disponíveis é realizada, sendo que a sua primeira aplicação em um ajuste de histórico foi proposta por Skjervheim et al. (2011). Devido ao fato de que os dados dinâmicos do modelo não são atualizados recursivamente como no EnKF, o ES na sua forma padrão tende a apresentar piores resultados em comparação com o EnKF. Sendo assim, uma solução empregada para contornar essa limitação é o uso de algoritmos iterativos, onde um ajuste de melhor qualidade pode ser obtido (Ma et al., 2017). Como solução do problema, Emerick e Reynolds (2013) propuseram um método iterativo (*Ensemble Smoother with Multiple Data Assimilation* – ES-MDA) onde os dados são assimilados múltiplas vezes usando um fator de inflação na covariância dos erros de medição com objetivo de amortecer cada etapa de assimilação. Desde então, o ES-MDA vem sendo constantemente empregado em problemas práticos de ajuste de histórico, apresentando bons resultados em geral (Maucec et al., 2016; Emerick, 2016; Breslavich et al., 2017). O objetivo deste trabalho é aplicar a metodologia do ES-MDA em um modelo de grande-escala e analisar a eficiência do ajuste de acordo com o tamanho do conjunto de modelos utilizado no ajuste de histórico.

## 2. Metodologia

A metodologia apresentada neste trabalho tem como objetivo aplicar o ES-MDA (Emerick e Reynolds, 2013) em um problema típico de ajuste de histórico de um modelo de campo, de forma que sejam analisados os efeitos do tamanho do conjunto de modelos utilizados no ajuste.

### 2.1 ES-MDA

No ajuste de histórico utilizando o ES-MDA (Emerick e Reynolds, 2013), a assimilação dos dados é composta basicamente de duas etapas, predição e análise. A etapa de predição relaciona a resposta do simulador e cada vetor contendo uma realização dos parâmetros incertos. Já na etapa de atualização, este conjunto de parâmetros é atualizado com base na diferença entre os valores simulados na etapa de previsão e os valores observados (as medições). Sendo assim, cada membro  $j$  do conjunto de tamanho  $N_e$  contendo os parâmetros do modelo é definido como:

$$m_j = \begin{bmatrix} m_1 \\ m_2 \\ \vdots \\ m_{N_m} \end{bmatrix}, \quad (1)$$

onde  $m$  é o vetor contendo todos os  $N_m$  parâmetros incertos do modelo que serão atualizados, como por exemplo, dados de porosidade e permeabilidade. A etapa de predição, que relaciona a resposta do simulador ( $d_j$ ) para cada membro  $j$  do conjunto pode ser expressa como:

$$d_j^i = g(m_j^i), \quad (2)$$

onde  $g$  é basicamente o simulador de reservatório utilizado e o sobrescrito  $i$  representa cada etapa de assimilação. No ES-MDA, as  $N_d$  medições ( $d_{obs}$ ) necessitam ser tratadas também como variáveis aleatórias, utilizando um conjunto de medições ruidosas ( $d_{obs,j}$ ), aplicando um ruído gaussiano nas medições de covariância  $C_D$ :

$$d_{obs,j} = d_{obs} + \sqrt{\alpha_i C_D^{1/2}} Z_d, \quad (3)$$

onde  $Z_d \sim \mathcal{N}(0, I_{N_d})$ . Em modelos de grande-escala e utilizando um conjunto de tamanho limitado, é necessário restringir a assimilação dos dados de acordo com a posição espacial de cada medição para reduzir atualizações espúrias e melhorar a qualidade do ajuste, esta restrição normalmente é denominada de ‘localização’ (Emerick e Reynolds, 2011; Chen e Oliver, 2016). Neste trabalho, a matriz de localização  $\rho$  foi aplicada diretamente no ganho de Kalman conforme mostrado na Equação 3. Desta forma, a etapa de análise no ES-MDA, que atualiza cada membro  $m_j$  do conjunto, pode ser expressa como:

$$m_j^{i+1} = m_j^i + \rho \circ \left[ C_{MD}^i (C_{DD}^i + \alpha_i C_D)^{-1} \right] (d_{obs,j} - d_j^i), \quad (4)$$

onde  $\alpha_i$  é o fator de inflação de cada etapa de assimilação,  $C_{MD}^i$  representa a matriz de covariância-cruzada entre os vetores de parâmetros do modelo e dos dados simulados,  $C_{DD}^i$  representa a matriz de auto-covariância entre os dados simulados. Vale ressaltar que no ES-MDA, as covariâncias são estimadas em torno da média do conjunto:

$$C_{MD}^i = \frac{1}{Ne - 1} \sum_{j=1}^{Ne} (m_j^i - \bar{m}^i)(m_j^i - \bar{m}^i)^T, \quad (5)$$

$$C_{DD}^i = \frac{1}{Ne - 1} \sum_{j=1}^{Ne} (d_j^i - \bar{d}^i)(d_j^i - \bar{d}^i)^T, \quad (6)$$

sendo que,  $\bar{m}^i$  e  $\bar{d}^i$  representam a média do conjunto de vetores de parâmetros do modelo e dos dados simulados, respectivamente. A escolha dos fatores de inflação  $\alpha$  deve obedecer a seguinte condição para uma correta distribuição dos parâmetros à posteriori (Emerick e Reynolds, 2013):

$$\sum_{i=1}^{N_i} \frac{1}{\alpha_i} = 1. \quad (7)$$

A Figura 1 ilustra o fluxo de trabalho contendo as etapas de aplicação do ES-MDA.

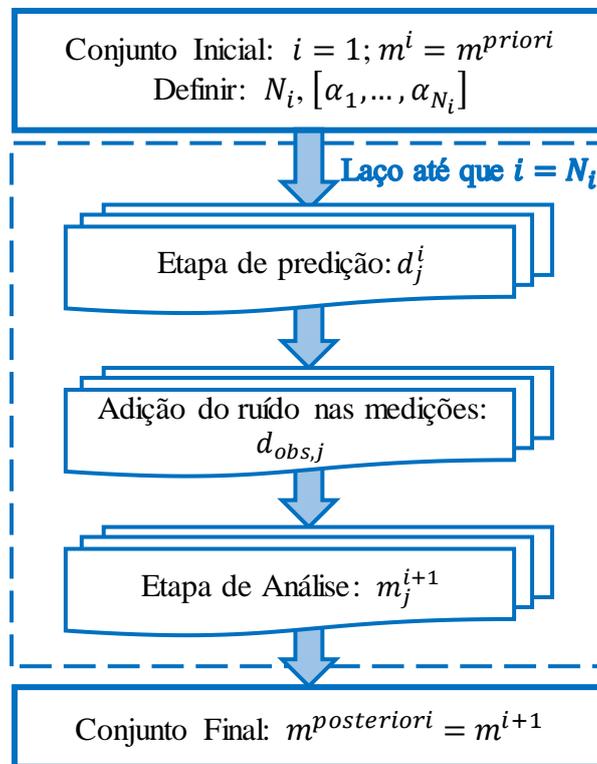


Figura 1 – Fluxo de trabalho do ES-MDA.

## 2.2 Função Objetivo

Uma das formas de comparar a qualidade do ajuste é através de uma função objetivo que represente a diferença entre os valores medidos e simulados. A função objetivo utilizada para realizar esta comparação mede basicamente o desvio quadrático entre os valores simulados e medidos, normalizados pelo inverso da matriz  $C_D$ , de forma que a variabilidade dos desvios para propriedades com diferentes magnitudes seja semelhante:

$$O(j, i) = \frac{1}{2Nd} (d_{obs} - d_j^i)^T C_D^{-1} (d_{obs} - d_j^i). \quad (8)$$

### 3. Estudo de caso

O modelo de simulação utilizado para a aplicação da metodologia foi o *benchmark* UNISIM-I, mais especificamente o estudo de caso UNISIM-I-H (Maschio et al., 2015), desenvolvido especificamente para aplicação de metodologias de ajuste de histórico, com uma estratégia de produção previamente otimizada contendo um histórico de produção. A construção do modelo foi baseada em dados públicos do campo de Namorado, localizado na bacia de Campos. Avansi e Schiozer (2015) detalham a construção do modelo. O UNISIM-I é um modelo sintético composto de um grid *corner point* (81x58x20) e possui 14 poços produtores e 11 poços injetores, a Figura 2 ilustra o modelo de simulação, que possui duas regiões produtoras separadas por uma falha selante. O estudo de caso possui 11 anos de histórico de produção, contendo dados mensais de vazões e pressões de fundo dos poços.

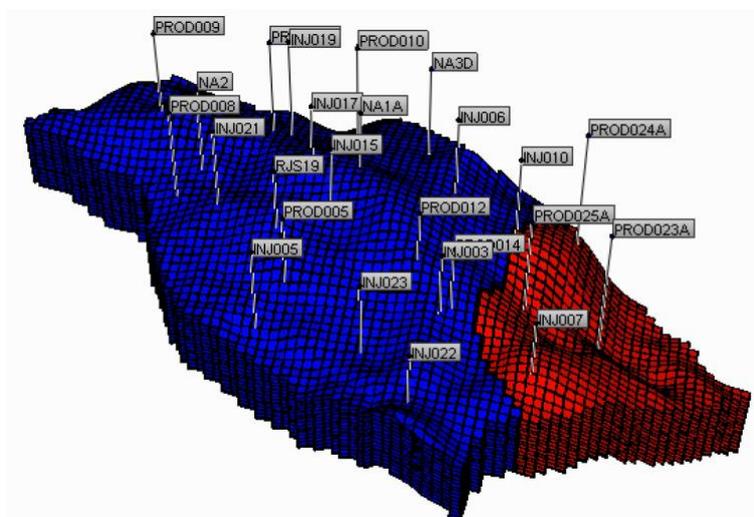


Figura 2 – Benchmark UNISIM-I-H.

As incertezas utilizadas no estudo são as descritas no estudo de caso, porém com algumas modificações em relação à curva de permeabilidade relativa à água, que são descritas no *benchmark* original como parâmetros discretos. Neste trabalho, a curva é expressa utilizando a correlação de Corey, considerando como parâmetros incertos a permeabilidade relativa à água na saturação de óleo residual (máxima), e o expoente de interpolação. A matriz de localização  $\rho$  foi construída utilizando a correlação proposta por Gaspari and Cohn (1999) e distância crítica equivalente a 20 blocos de simulação, baseado em trabalhos anteriores (Silva et al., 2017). Como mencionado anteriormente, os dados de histórico necessitam ser tratados como variáveis aleatórias, aplicando um ruído gaussiano nos valores medidos. A Tabela 1 apresenta os dados que foram assimilados e seus respectivos erros de medição utilizados neste trabalho. Em todos os casos deste estudo, o número de iterações e o fator de inflação utilizados foram constantes ( $N_i = 4$ ;  $\alpha_1, \dots, \alpha_4 = 4$ ). Foram analisados 3 casos, variando o tamanho do conjunto ( $N_e = [100, 300, 500]$ ) de tal forma que fosse possível verificar a influência do tamanho do conjunto nos resultados da assimilação utilizando o ES-MDA.

Tabela 1–Erros de medição.

Medição	Erro
Vazão de produção de óleo	10% (min. 1 m <sup>3</sup> /d)
Vazão de produção de água	15% (min. 1 m <sup>3</sup> /d)
Razão Gás/óleo	20% (min. 10 m <sup>3</sup> /d)
Vazão de injeção de água	05% (min. 1 m <sup>3</sup> /d)
Pressão de fundo	5 kgf/cm <sup>2</sup>

#### 4. Resultados e Discussão

Uma das formas mais simples de verificar a eficiência de um ajuste é analisar a resposta do simulador antes e após o ajuste dos parâmetros. Neste contexto, foram selecionados um poço produtor e um injetor, com objetivo de verificar visualmente a eficiência do ES-MDA ao longo de cada iteração. É possível observar nas Figuras 3 e 4 que a resposta do conjunto de modelos após o ajuste consegue representar melhor os dados disponíveis do que o conjunto de modelos inicial.

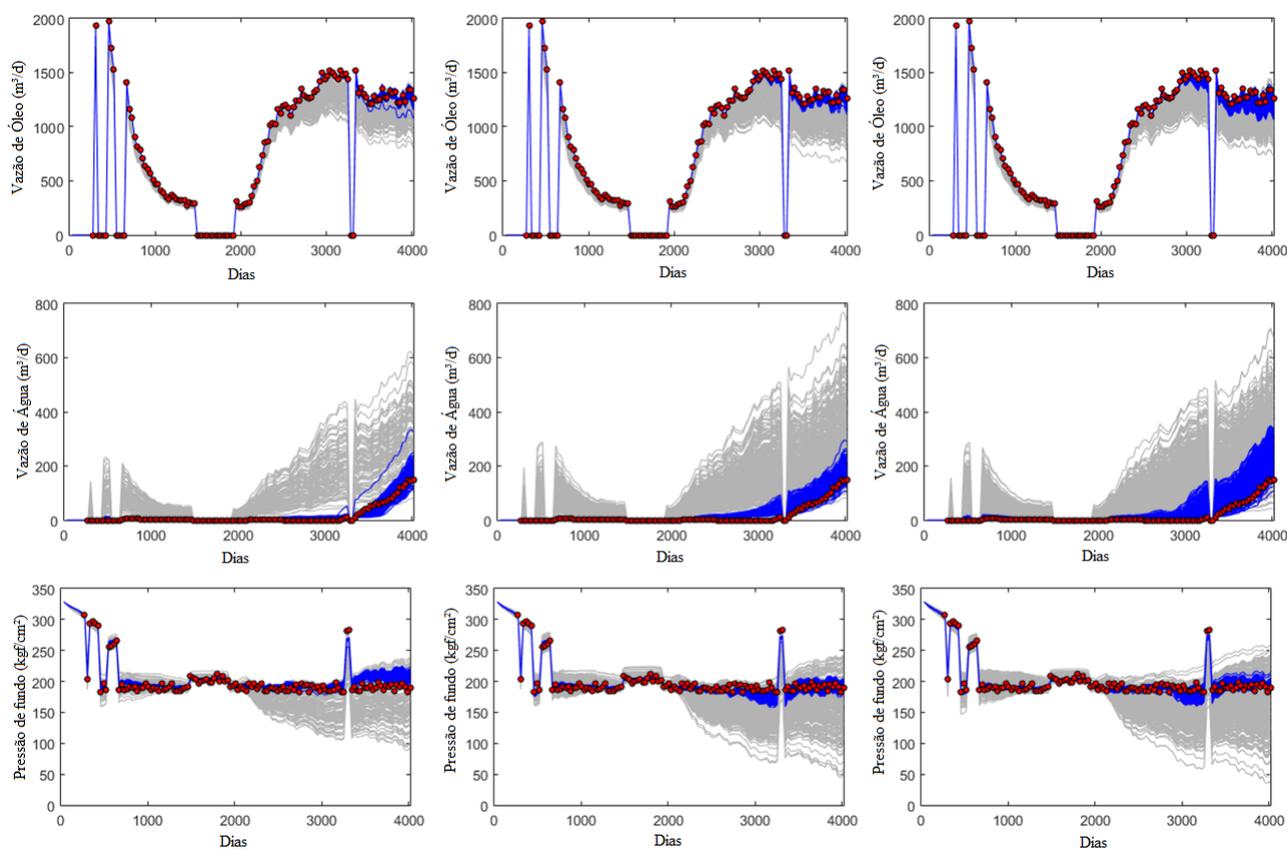


Figura 3 – Vazão de produção de óleo, de água e pressão de fundo do poço produtor NA3D para  $N_e = 100$  (esquerda),  $N_e = 300$  (centro),  $N_e = 500$  (direita). As linhas cinza representam a resposta à priori, as linhas azuis representam a resposta à posteriori e os pontos em vermelho representam as medições.

Utilizando a função objetivo descrita anteriormente (Equação 8), é possível verificar a qualidade do ajuste de cada caso. A Figura 5 ilustra os valores médios da função objetivo para cada caso. A partir da figura é possível verificar que todos os casos apresentam um ajuste de qualidade equivalente.

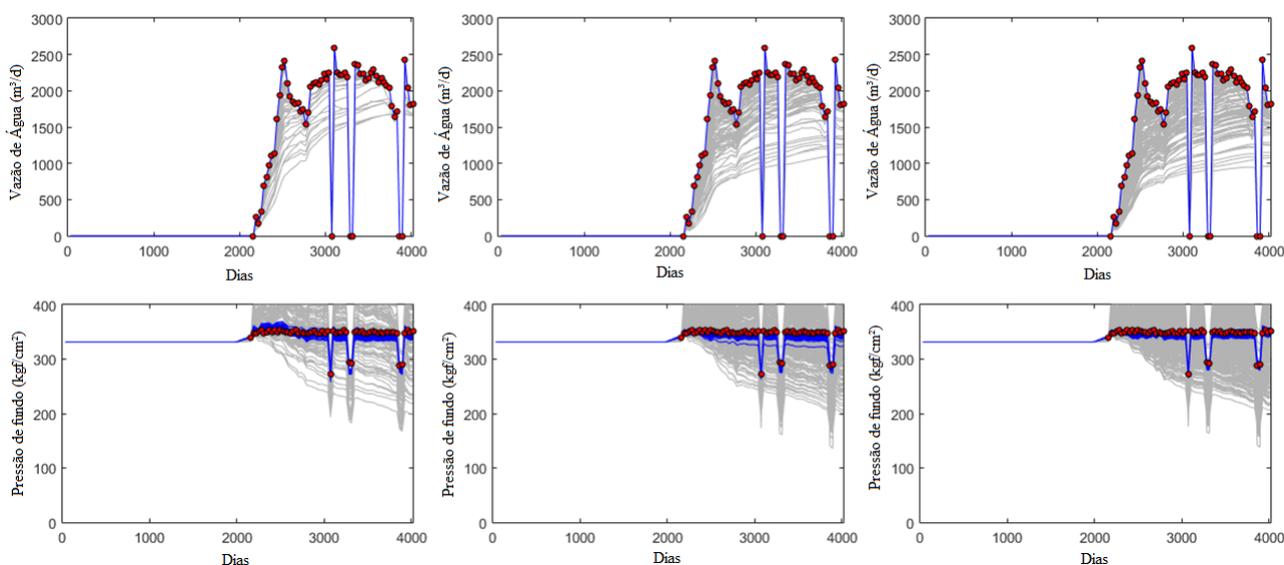


Figura 4 – Vazão de injeção de água e pressão de fundo do poço injetor INJ010 para  $N_e = 100$  (esquerda),  $N_e = 300$  (centro),  $N_e = 500$  (direita). As linhas cinza representam a resposta a priori, as linhas azuis representam a resposta à posteriori e os pontos em vermelho representam as medições.

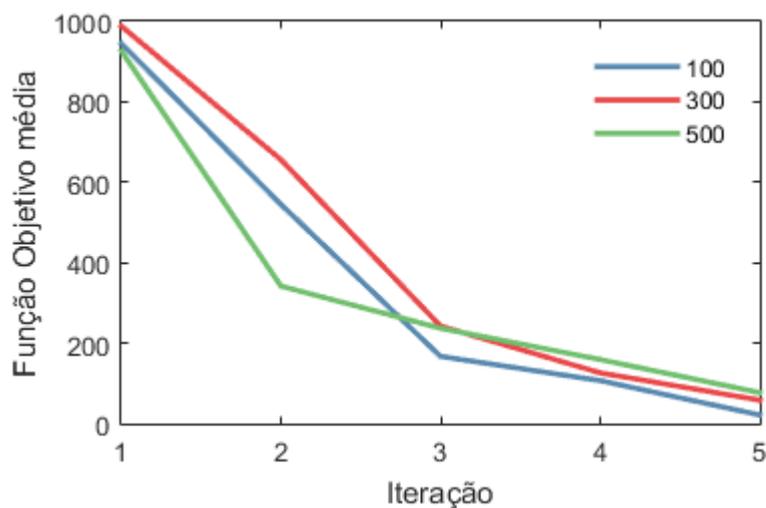


Figura 5 – Média da função objetivo do conjunto em cada etapa de iteração para todos os casos analisados.

Outro resultado que deve ser analisado é de que forma ocorreram as atualizações dos parâmetros incertos durante a realização do ajuste de histórico. Um parâmetro importante é a variabilidade do conjunto após a aplicação do ES-MDA, desejando-se evitar uma grande perda de variabilidade (colapso do conjunto), que pode levar a uma subestimação das incertezas do modelo. Isto pode ocasionar uma má previsão de toda a vida útil do mesmo, já que o conjunto atualizado pode não estar mais contemplando as reais incertezas deste modelo. A Figura 6 ilustra a média e o desvio padrão da permeabilidade na direção  $i$  do conjunto inicial e dos conjuntos após a aplicação do ES-MDA. É possível observar uma menor perda de variabilidade quanto maior o conjunto. Este fenômeno pode ser explicado devido um mau condicionamento das matrizes de covariância  $C_{MD}^i$  e  $C_{DD}^i$ , já que as mesmas são calculadas em torno da média do conjunto.

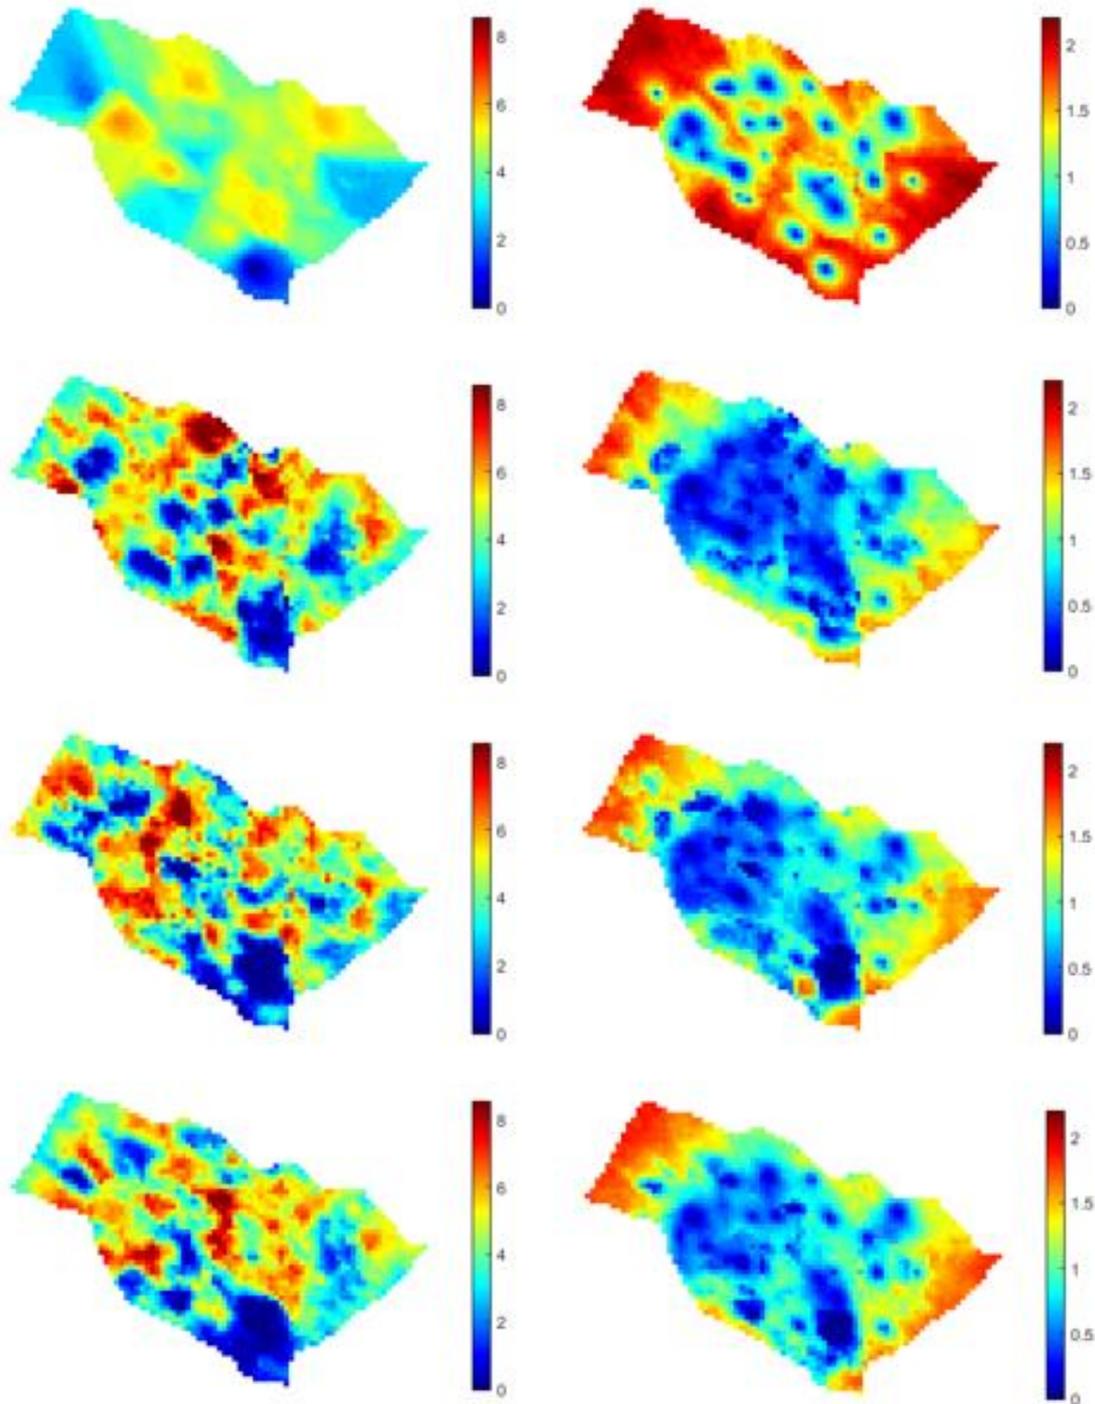


Figura 6 – Média (esquerda) e desvio padrão (direita) de  $\ln k_i$  do topo do reservatório (camada 1). De cima para baixo: 1) Inicial, 2)  $N_e = 100$ , 3)  $N_e = 300$ , 4)  $N_e = 500$ .

Este mesmo colapso do conjunto pode ser verificado ao analisar o comportamento das propriedades escalares (aplicáveis em todo o campo) após a realização do ajuste de histórico. A Figura 7 ilustra o desvio padrão da compressibilidade da rocha para o conjunto inicial e para o conjunto final de cada caso. É possível verificar que quanto menor o tamanho do conjunto, menor é desvio padrão das propriedades atualizadas.

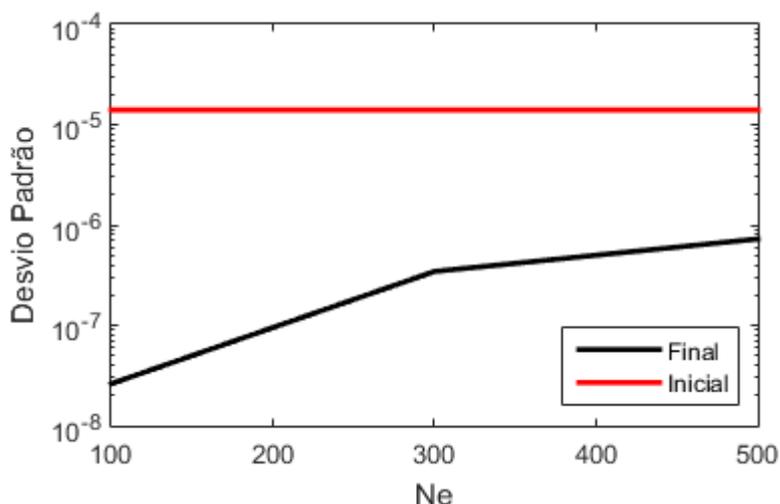


Figura 7 – Desvio padrão da compressibilidade da rocha para os conjuntos atualizados e o conjunto inicial.

## 5. Conclusões

Neste trabalho, foi aplicado o ES-MDA com localização no processo de ajuste de histórico. A metodologia aplicada no estudo de caso apresentou um ajuste de histórico de boa qualidade, conforme pôde ser observado qualitativamente e quantitativamente. As maiores dificuldades e deficiências encontradas são em relação a correlações espúrias e grande perda de variabilidade do conjunto de modelos, que pode resultar em uma má estimativa das incertezas do reservatório ocasionando uma má previsão da vida útil do campo, mesmo com um bom ajuste de histórico. Este fato pode ser mitigado aplicando metodologias adaptativas, onde os amortecimentos de cada iteração, assim como o número de iterações são definidos automaticamente.

## 6. Agradecimentos

Os autores agradecem a Escola Politécnica da Universidade de São Paulo, CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) e LASG (Laboratório de Simulação e Gerenciamento de Reservatórios de Petróleo) pelo suporte fornecido para a elaboração deste trabalho. Os autores agradecem igualmente à CMG (Computer Modelling Group Ltd.) pelo fornecimento das licenças necessárias para a elaboração deste trabalho.

## 7. Referências

- AVANSI, G.D., SCHIOZER, D.J., 2015. UNISIM-I: Synthetic Model for Reservoir Development and Management Applications. *International Journal of Modeling and Simulation for the Petroleum Industry* 9 (1), 21-30. ISSN: 1982-6028.
- BRESLAVICH, I.D., SARKISOV, G.G., MARAKOVA, E.S., 2017. Experience of MDA Ensemble Smoother Practice for Volga-Ural Oilfield. In: *Proceedings of the SPE Russian*

- Petroleum Technology Conference, 16-18 October, Moscow, Russia, number SPE 187800. <https://doi.org/10.2118/187800-MS>.
- EMERICK, A.A., REYNOLDS, A.C., 2013. Ensemble Smoother with multiple data assimilation. *Computers & Geosciences* 55, 3-15. <https://doi.org/10.1016/j.cageo.2012.03.011>.
- EMERICK, A.A., 2016. Analysis of the performance of ensemble-based assimilation of production and seismic data. *Journal of Petroleum Science and Engineering* 139, 219-239. <https://doi.org/10.1016/j.petrol.2016.01.029>.
- EVENSEN, G., 1994. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. *Journal of Geophysical Research* 99 (C5), 10143-10162. <https://doi.org/10.1029/94JC00572>.
- EVENSEN, G., 2003. The Ensemble Kalman Filter: theoretical formulation and practical implementation. *Ocean Dynamics*. 53, 343-367. <https://doi.org/10.1007/s10236-003-0036-9>.
- GASPARI G., COHN, S.E., 1999. Construction of correlation functions in two and three dimensions. *Quarterly Journal of the Royal Meteorological Society* 125 (554), 723-757. <https://doi.org/10.1002/qj.49712555417>.
- MA, X., HETZ, G., WANG, X., BI, L., HODA, N., 2017. A Robust Iterative Ensemble Smoother Method for Efficient History Matching and Uncertainty Quantification. In: *Proceedings of SPE Reservoir Simulation Conference*, 20-22 February, Montgomery, Texas, USA, number SPE 182693. <https://doi.org/10.2118/182693-MS>.
- MASCHIO, C., AVANSI, G., SCHIOZER, D., SANTOS, A., 2015. Study Case for History Matching and Uncertainties Reduction based on UNISIM-I Field. Available online: [www.unisim.cepetro.unicamp.br/benchmarks/br/unisim-i/unisim-i-h](http://www.unisim.cepetro.unicamp.br/benchmarks/br/unisim-i/unisim-i-h).
- MAUCEC, M., RAVANELLI, F.M., LYNGRA, S., ZHANG, S.J., ALRAMADHAN, A.A., ABDELHAMID, O.A., AL-GARNI, S.A., 2016. Ensemble-Based Assisted History Matching with Rigorous Uncertainty Quantification applied to a Naturally Fractured Carbonate Reservoir. In: *Proceedings of the SPE Annual Technical Conference & Exhibition*, 26-28 September, Dubai, UAE, number SPE 181325. <https://doi.org/10.2118/181325-MS>.
- SILVA, V.L.S., EMERICK, A.A., COUTO, P., ALVES, J.L.D., 2017. History matching and production optimization under uncertainties – Application of closed-loop reservoir management. *Journal of Petroleum Science and Engineering* 157, 860-874. <https://doi.org/10.1016/j.petrol.2017.07.037>.
- SKJERVHEIM, J.-A., EVENSEN, G., HOVE, J., VABØ, J.G., 2011. An Ensemble Smoother for assisted History Matching. In: *Proceedings of the SPE Reservoir Simulation Symposium*, 21-23 February, The Woodlands, Texas, USA, number SPE 141929. <https://doi.org/10.2118/141929-MS>.
- VAN LEEUWEN, P.J., EVENSEN, G., 1996. Data Assimilation and Inverse Methods in Terms of a Probabilistic Formulation. *Monthly Weather Review* 124, 2898-2913. [https://doi.org/10.1175/1520-0493\(1996\)124<2898:DAAIMI>2.0.CO;2](https://doi.org/10.1175/1520-0493(1996)124<2898:DAAIMI>2.0.CO;2).