



República Federativa do Brasil
Ministério do Desenvolvimento, Indústria
e do Comércio Exterior
Instituto Nacional da Propriedade Industrial

(21) **PI0618812-5 A2**

(22) Data de Depósito: 14/11/2006
(43) Data da Publicação: 13/09/2011
(RPI 2123)



(51) *Int.Cl.:*
G06G 7/48

(54) Título: MÉTODOS PARA ATUALIZAR UM CONJUNTO DE MODELOS DE RESERVATÓRIO E PARA ASSIMILAR DADOS EM UM CONJUNTO DE MODELOS, DISPOSITIVO DE ARMAZENAMENTO DE PROGRAMA E APARELHO DE SIMULAÇÃO PARA ATUALIZAR UM CONJUNTO DE MODELOS DE RESERVATÓRIO

(30) Prioridade Unionista: 21/11/2005 US 11/285606

(73) Titular(es): CHEVRON U.S.A. INC.


(72) Inventor(es): Wen H. Chen, Xian-Huan Wen

(74) Procurador(es): Momsen, Leonardos & CIA.

(86) Pedido Internacional: PCT US2006044155 de 14/11/2006

(87) Publicação Internacional: WO 2007/061686 de 31/05/2007

(57) Resumo: MÉTODOS PARA ATUALIZAR UM CONJUNTO DE MODELOS DE RESERVATÓRIO E PARA ASSIMILAR DADOS EM UM CONJUNTO DE MODELOS, DISPOSITIVO DE ARMAZENAMENTO DE PROGRAMA E APARELHO DE SIMULAÇÃO PARA ATUALIZAR UM CONJUNTO DE MODELOS DE RESERVATÓRIO. Um método, sistema e aparelho para atualização de modelo de reservatório em tempo real usando conjunto de filtros de Kalman são descritos. O método inclui uma etapa de conformidade para colocar variáveis de estado estáticas e dinâmicas em conformidade umas com as outras durante uma etapa de tempo da atualização. Também, um método de atenuação iterativo é usado em conjunção com a etapa de conformidade para levar em conta características não Gaussianas e não lineares em um sistema. Também, um método de re-experimento é descrito, que reduz o tamanho de conjunto de modelos de reservatório que devem ser atualizados.



“MÉTODOS PARA ATUALIZAR UM CONJUNTO DE MODELOS DE
RESERVATÓRIO E PARA ASSIMILAR DADOS EM UM CONJUNTO
DE MODELOS, DISPOSITIVO DE ARMAZENAMENTO DE
PROGRAMA E APARELHO DE SIMULAÇÃO PARA ATUALIZAR UM
5 CONJUNTO DE MODELOS DE RESERVATÓRIO”

CAMPO TÉCNICO

A presente invenção refere-se geralmente a simuladores de
reservatório para prever o fluxo de fluidos através de formações subterrâneas,
e mais particularmente, a métodos de atualização de modelos de simulador de
10 reservatório para serem consistentes com os atuais dados de produção
medidos utilizando conjunto de filtro de Kalman (EnKF).

FUNDAMENTOS DA INVENÇÃO

Modelos de reservatório obtiveram uma importante parte da
análise de decisão do dia a dia, correlacionada com gestão de campos de
15 petróleo/gás. O conceito de gestão de reservatório de ‘circuito fechado’ está
atualmente recebendo considerável atenção na indústria de petróleo. Uma
técnica de atualização de modelo de reservatório de ‘tempo real’ ou contínuo
é um componente importante para a aplicação factível de qualquer gestão de
reservatório de circuito fechado. Esta técnica deve ser capaz de atualizar
20 rapidamente e continuamente modelos de reservatório que assimilam os dados
de produção medidos, atualizados, de modo que as previsões de desempenho
e as incertezas associadas são atualizados para cálculos de otimização.

O conceito de gestão de reservatório de circuito fechado
permite que sejam tomadas decisões em tempo real que maximizam o
25 potencial de produção de um reservatório. Estas decisões são baseadas na
informação mais corrente disponível sobre o modelo de reservatório e a
incerteza associada da informação. Uma exigência importante neste processo
de gestão de reservatório, em tempo real, baseado em modelo, é a capacidade
de estimar rapidamente os modelos de reservatório e a incerteza associada que

reflete os dados de produção mais correntes em uma maneira em tempo real. Tradicionalmente, a validação de modelos de reservatório em comparação com dados de produção é realizada através de um processo de correspondência de história (HM). Os métodos de correspondência de história
5 convencionais apresentam uma ou mais das seguintes desvantagens:

(1) dados de produção para toda a história são colocados em correspondência ao mesmo tempo e repetidos para simulações de fluxo de toda a história são requeridos, os quais tornam o HM extremamente demorado.

10 (2) métodos de HM baseados em gradiente requerem cálculos de coeficiente de sensibilidade e minimização, os quais são complicados, intensivos em termos de CPU, e com frequência aprisionados por meio de mínimos locais; e

(3) é difícil determinar incerteza com os métodos tradicionais e
15 pode envolver repetição do processo de correspondência de história com diferentes modelos iniciais (isto raramente é feito por causa do tempo envolvido para atingir uma única correspondência de história).

Assim, a despeito do significativo progresso feito academicamente e praticamente, os tradicionais métodos de correspondência
20 de história não bem apropriados para a atualização de modelo em tempo real. Isto é particularmente verdadeiro quando uma grande quantidade de dados é disponível (por exemplo, a partir de sensores permanentes) e a rápida atualização de múltiplos modelos é requerida.

O método de atualização de conjunto de filtro de Kalman
25 (EnKF) é bem apropriado para tais aplicações em comparação com os tradicionais métodos de correspondência de história. As raras características do conjunto de filtro de Kalman são resumidas abaixo:

(1) EnKF incrementalmente atualiza modelos de reservatório que assimilam dados de produção sequencialmente com o tempo quando eles

se tornam disponíveis, assim ele é idealmente apropriado para aplicações em tempo real;

(2) um conjunto de modelos de reservatório que reflete os dados de produção mais correntes é sempre mantido. Assim, as previsões de desempenho e incerteza são sempre disponíveis para estudo de otimização;

(3) EnKF é computacionalmente rápido por causa da eficiência de computação paralela/de distribuição;

(4) EnKF pode ser aplicado com qualquer simulador de reservatório sem a necessidade de codificação complicada; e

(5) EnKF não precisa de cálculos de otimização e de coeficientes de sensibilidade.

Estas características tornam o EnKF ideal para atualização de modelo de reservatório em tempo real. Desde sua introdução, o EnKF foi amplamente usado em Meteorologia e Oceanografia para assimilação de dados em grandes sistemas não lineares. Evensen, G.: "Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte-Carlo methods to forecast error statistics" Monthly Weather Review, 127(12), 2741-2758, 1999. Houtekamer, P.X. e Mitchell, H.L.: "Data assimilation using an ensemble Filtro de Kalman technique" Monthly Weather Review, 126(3), 796-811, 1998. Van Leeuwen, P.J. e Evensen, G.: "Data assimilation and inverse methods in terms of probabilities formulation", Monthly Weather Review 124, 2898-2913, 1996. Reichle, R.H., McLaughlin, D.B., e Entekhabi, D.: "Hydrologic data assimilation with the ensemble Kalman filter", Monthly Weather Review, 130(1) 103-114, 2002. Burgers, G., van Leeuwen, P.J. e Evensen, G.: "Analysis scheme in the ensemble Kalman filter", Monthly Weather Review, 126, 1719-1724, 1998. Evensen, G.: "The ensemble Kalman filter: Theoretical formulation and practical implementation" Ocean Dynamics, 53(4), 343-367, 2003.

O conjunto de filtro de Kalman foi recentemente introduzido

na indústria do petróleo. Gu, Y. e Oliver, D. S.: “The ensemble Kalman filter for continuous updating of reservoir simulation models”, Computational Geosciences, em impressão, 2005; Nasvdal, G., Mannseth, T., e Vefring, E.H.: “Near-well reservoir monitoring through ensemble Kalman filter”

- 5 Folheto da SPE 75235 apresentado no Simpósio de Recuperação de Petróleo Aperfeiçoada da SPE/DOE (SPE/DOE no Simpósio de Recuperação de Petróleo Aperfeiçoada), 13-18 de abril de 2002; e Naevdal, G., Johnsen, L.M., Aanonsen, S.I., e Vefring, E.H.: “Reservoir monitoring and continuous model updating using ensemble Kalman filter” , Folheto da SPE 84372, apresentado
- 10 na Conferência Técnica Anual e Exibição da SPE 2003 SPE (‘Annual Technical Conference and Exhibition’), Denver, CO, 5-8 de outubro de 2003.

- O conjunto de filtro de Kalman pode também ser usado como uma técnica de correspondência de história. Gu, Y. e Oliver, D. S.: “History matching of the PUNQ-S3 reservoir model using the ensemble Kalman
- 15 filter”, Folheto da SPE 89942 apresentado na 2004 Conferência Técnica Anual e Exibição da SPE (SPE Annual Technical Conference e Exhibition), Houston, TX, 26-29 de setembro de 2004; Liu, N. e Oliver, D. S.: “Critical evaluation of ensemble Kalman filter on history matching of geological
 - 20 facies”, Folheto da SPE 92867 apresentado no 2005 Simpósio de Simulação de Reservatório da SPE (2005 SPE Reservoir Simulation Symposium), Houston, TX, 31 de janeiro - 2 de fevereiro de 2005; Lorentzen, R.J., Naevdal, G., Valles, B., Berg, A.M. e Grimstad, A.A.: “Analysis of the ensemble Kalman filter for estimation of permeability and porosity in reservoir models”, SPE 96375, apresentado na 2005 Simpósio de Simulação de
 - 25 Reservatório da SPE (2005 SPE Reservoir Simulation Symposium) havida em Dallas, Texas, 9-12 de outubro de 2005; e Tarantola, H.: Teoria de Problema Inverso: “Inverse Problem Theory: Methods for Data Fitting e Model Parameter Estimation”. Elsevier, Amsterdã, Países Baixos, pp. 613, 1987.

Todavia, as metodologias correntes de EnKF têm um número

de deficiências. Primeira, o EnKF convencional falha em solucionar equações de fluxo depois de atualização de filtro de Kalman, de modo que as variáveis estáticas e dinâmicas atualizadas podem não ser consistentes, ou seja, as soluções das equações de fluxo com base nas variáveis estáticas atualizadas podem ser diferentes das variáveis dinâmicas atualizadas. Segunda, os métodos EnKF convencionais falham para levar em conta a não linearidade e outras suposições feitas durante atualização de Kalman. Ainda, o EnKF convencional tipicamente requer grande tamanho de conjuntos para assegurar precisão. A presente invenção aborda estas deficiências nos métodos EnKF convencionais.

SUMÁRIO DA INVENÇÃO

A presente invenção provê um método, sistema e aparelho para atualização de modelo de reservatório em tempo real usando um conjunto de filtro de Kalman. O método compreende as seguintes etapas. Um conjunto de modelos de reservatório é gerado. O conjunto é representado, em uma primeira etapa de tempo, por meio de um vetor de estado inicial de variáveis de estado estáticas e dinâmicas. Por exemplo, as variáveis de estado estático podem incluir porosidade e/ou permeabilidade. As variáveis dinâmicas de estado podem incluir pressão e saturação. De uma primeira etapa de tempo para uma segunda etapa de tempo, o vetor de estado inicial é previsto em avanço para computar um vetor de estado previsto que inclui variáveis estáticas e dinâmicas de previsão e dados de produção de previsão. Um ganho, preferivelmente um ganho de Kalman, é computado com base em variáveis de estado previstas e nos dados de produção de previsão. Um vetor de estado atualizado de variáveis de estado estáticas e dinâmicas atualizadas é então computado utilizando o ganho computado, bem como os dados de produção observados e os dados de produção de previsão. A seguir, a vetor de estado de conformidade é criado incluindo as variáveis de estado estático atualizadas e as variáveis dinâmicas de estado. Finalmente, da primeira etapa

de tempo para a segunda etapa de tempo, o vetor de estado de conformidade é previsto em avanço para computar um vetor de estado de conformidade previsto que inclui variáveis de estado estáticas e dinâmicas previstas. Por conseguinte, o conjunto de modelos de reservatório é atualizado com as variáveis de estado estáticas e dinâmicas do vetor de estado de conformidade previsto estando em conformidade um com o outro. Também, um método de atenuação iterativo pode ser usado em conjunção com a etapa de conformidade para levar em conta não linearidade em um problema inverso geral através de uma iteração externa com uma atualização de atenuação. Ainda, um método é provido, o qual reduz o tamanho de conjunto de modelos de reservatório que devem ser atualizados.

É um objetivo da presente invenção prover um método de conformar variáveis estáticas e dinâmicas de modelos de reservatório durante o uso de um método de filtragem de conjunto de Kalman.

É outro objetivo prover um método de filtragem de conjunto de Kalman em que iterações são usadas para corrigir suposições Gaussianas e lineares em um sistema.

É ainda outro objetivo prover uma técnica de experimentação para selecionar um subconjunto de conjuntos a partir de um grande tamanho de conjuntos, que assegura precisão enquanto reduz o número de conjuntos necessários para precisamente executar o EnKF.

BREVE DESCRIÇÃO DOS DESENHOS

A figura 1 é um desenho esquemático de um procedimento de conjunto de filtro de Kalman (EnKF) não-iterativo (seguindo as setas sólidas) e um processo de conformidade de EnKF (seguindo as setas grossas e setas tracejadas (1) então (2);

a figura 2 é um desenho esquemático de um processo de EnKF iterativo (seguindo o processo de conformidade de EnKF) com iterações executadas durante etapas de atualização;

a figura 3 é um gráfico de uma função de distribuição cumulativa (cdf) de pressão de fundo de poço (BHP) e a experimentação do membro de modelo uniformemente a partir de cdf;

as figuras 4(A)-(D) mostram um campo de permeabilidade de referência e gráficos de dados de produção;

as figuras 5(A)-(D) ilustram gráficos com média (esquerda) e desvios padrões (direita) da BHP em um primeiro poço de produção P1 e produção marinha (WPR) em um terceiro poço de produção P3 usando o processo de atualização EnKF não-iterativo;

as figuras 6(A)-(D) mostram gráficos com média (esquerda) e desvio padrão (direita) da BHP em P1 e WPR usando o processo de atualização EnKF iterativo;

as figuras 7(A)-(D) mostram média e variância de 200 modelos de permeabilidade atualizados em 60 e 120 dias usando o processo de atualização EnKF não-iterativo. As linhas tracejadas são os resultados a partir do modelo verdadeiro;

as figuras 8(A)-(D) mostram média e variância de 200 modelos de permeabilidade atualizados em 60 e 120 dias usando o processo de atualização EnKF iterativo;

as figuras 9(A)-(C) são gráficos da alteração de uma função objetiva durante iteração em diferentes tempos de assimilação;

as figuras 10(A)-(H) são gráficos de valores de permeabilidade atualizados por meio do EnKF iterativo em diferentes iterações e os correspondentes dados de produção computados a partir de modelos de permeabilidade atualizados. Cruzes representam a média dos 200 modelos e pontos ocos são o valor verdadeiro/observado;

as figuras 11(A)-(B) são gráficos de valores de permeabilidade atualizados por meio do EnKF não-iterativo em 30 dias e dados de produção computados a partir dos modelos de permeabilidade atualizados. Cruzes são a

média dos 200 modelos e os pontos ociosos são os valores verdadeiros/observados;

as figuras 12(A)-(D) mostram gráficos com a média (topo) e desvio padrão (fundo) de dados de produção previstos usando modelos de permeabilidade atualizados em 60 dias; linhas tracejadas são para dados verdadeiros, linhas sólidas são resultados do EnKF não-iterativo, e linhas tracejadas são resultados do EnKF iterativo;

as figuras 13(A)-(D) mostram gráficos com a média (topo) e desvios padrões (fundo) de dados de produção previstos, adaptados a modelos de permeabilidade atualizados em 120 dias; linhas tracejadas são dados verdadeiros, linhas tracejadas são resultados do EnKF não-iterativo, e linhas tracejadas são resultados do EnKF iterativo; (Note a precisão aperfeiçoada e incerteza reduzida em comparação com os resultados da figura 12);

a figura 14 mostra uma função de distribuição cumulativa (cdf) da variável que mais varia (BHP em um poço de produção P1);

as figuras 15(A)-(F) mostram gráficos de dados de produção simulados para toda a história usando os modelos atualizados na última etapa de tempo (720 dias) com diferentes jogos de conjuntos iniciais; as linhas brancas são os resultados verdadeiros;

as figuras 16(A)-(C) representam histogramas da pressão de fundo de poço prevista (BHP) no poço de produção P1 em 720 dias a partir dos modelos atualizados na última etapa de tempo com diferentes jogos de conjuntos iniciais (círculos pretos são os resultados verdadeiros.);

as figuras 17(A)-(H) ilustram média e variância de 200 modelos de permeabilidade atualizados em 300 dias com diferente intervalo de tempo de assimilação Δ_t usando um esquema de atualização EnKF não-iterativo;

as figuras 18(A)-(H) mostram a média e variância de 200 modelos de permeabilidade atualizados em 300 dias diferentes intervalos de

tempo de assimilação Δ_t usando o EnKF iterativo;

as figuras 19(A)-(H) mostram gráficos de dados de produção com base nos modelos atualizados em 300 dias usando o esquema de atualização EnKF não iterativo. As linhas brancas são a partir do campo de referência e as linhas tracejadas são a média das previsões;

as figuras 20(A)-(H) mostram gráficos de predições de dados de produção com base nos modelos atualizados em 300 dias usando o EnKF iterativo. As linhas brancas são a partir do campo de referência e linhas tracejadas são a média das predições;

as figuras 21(A)-(H) mostram gráficos de valores de permeabilidade atualizados por meio do EnKF iterativo em diferentes iterações e os correspondentes dados de produção computados a partir dos modelos de permeabilidade atualizados em 300 dias. As cruzes são a média dos 200 modelos e os pontos ocos são os dados verdadeiros/observados; e

as figuras 22(A)-(B) mostra gráficos de valores de permeabilidade atualizados por meio do EnKF não-iterativo em 300 dias e dados de produção computados a partir dos modelos de permeabilidade atualizados. Cruzes são a média dos 200 modelos e pontos ocos são o valor verdadeiro/observado.

DESCRIÇÃO DETALHADA DA INVENÇÃO

A metodologia EnKF convencional será primeiramente descrita. Esta metodologia corresponde ao percurso mostrado por meio das setas sólidas na figura 1. Então, um método é descrito, o qual coloca os parâmetros estáticos e dinâmicos em conformidade. Este método emprega etapas de conformidade que são incorporadas na metodologia EnKF convencional. As etapas de conformidade adicionadas são mostradas por meio das setas tracejadas na figura 1. Em seguida, um processo de iteração na metodologia de atualização de EnKF é introduzido, o qual aborda possíveis características não-Gaussianas e não lineares no sistema de reservatório. Ver a

figura 2. Um método de re-experimento é então descrito, o qual reduz o tamanho de conjunto de modelos de reservatório que devem ser atualizados. A sensibilidade de uso de diferentes intervalos de tempo de assimilação é também investigada. Uma metodologia de EnKF de exemplo, praticada de acordo com a presente invenção, é então usada em conjunção com um exemplo de 2D sintético para mostrar as vantagens a serem ganhas usando aspectos da presente invenção.

Atualização de Conjunto de Filtro de Kalman

A atualização de EnKF é uma proposta Bayesiana e é inicializada por meio de geração de um conjunto de modelos de reservatório iniciais usando assunções geoestatísticas a priori. Dados de produção são incorporados seqüencialmente no tempo e os modelos de reservatório são atualizados quando novos dados de produção são introduzidos. A atualização de EnKF consiste de três processos em cada etapa de tempo: (1) previsão com base nas correntes variáveis de estado (ou seja, solução de equações de fluxo com variáveis estáticas e dinâmicas correntes), (2) data assimilação (computação de ganho de Kalman), e (3) atualização de variáveis de estado. A evolução de variáveis dinâmicas é ditada por meio das equações de fluxo.

Variáveis de estado incluem três tipos de variáveis: variáveis estáticas (por exemplo, campos de permeabilidade e porosidade que são tradicionalmente chamadas estáticas porque elas não variam com o tempo. Todavia, na proposta de EnKF, as variáveis estáticas são atualizadas com o tempo e assim são alteradas com o tempo representando a absorção da nova informação a partir dos dados. Esta noção “estática” é usada para conveniência de conceitos tradicionais), variáveis dinâmicas (por exemplo, pressão e saturações de fase de todo o modelo, que são soluções das equações de fluxo), e dados de produção (por exemplo, taxa de produção de poço, pressão de fundo de poço, taxa de produção/injeção de fase, corte de água, etc. que são usualmente medidos em poços). O conjunto de variáveis de

estado é modelado por meio de múltiplas realizações de modo que

$$y_{k,j} = \begin{bmatrix} m_s \\ m_d \\ d \end{bmatrix}_{k,j} \quad (1)$$

onde $y_{k,j}$ é o j -ésimo membro de conjunto do vetor de estado no instante t_k . m_s e m_d são vetores de variável estática e dinâmica, e d é o vetor de dado de produção. Em uma forma de concretização de exemplo preferida, m_s é a permeabilidade em cada célula do modelo de reservatório com dimensão de N sendo o número total de células ativas, m_d inclui pressão e saturação de água (modelo de duas fases) em cada célula (com dimensão de $2N$), e d inclui pressão de fundo de poço, taxa de produção de petróleo e taxa de produção marinha em poços com dimensão de $N_{d,k}$. A dimensão do vetor de estado é $N_{y,k}$ que pode se alterar com o tempo t_k para levar em conta diferentes quantidades de dados de produção em diferentes instantes. Nomenclatura associada com as equações usadas na presente descrição pode ser encontrada no final desta descrição. Aqueles versados na arte apreciarão que outras variáveis e dados estáticos, dinâmicos de produção, outros que não as variáveis e os dados acima mencionados, podem também ser usados com e estão dentro do escopo da presente invenção.

O processo de etapa-por-etapa de um tradicional EnKF é descrito, como segue (ver a figura 1, seguindo as setas sólidas):

- O filtro é inicializado por meio de geração de conjuntos de vetores estáticos e dinâmicos iniciais. Não existem dados de produção disponíveis no instante inicial (Existe uma variedade de métodos que podem ser usados para gerar um conjunto inicial). Nesta forma de concretização de exemplo, um método geoestatístico, tal como Simulação Gaussiana Sequencial, é usado para gerar realizações múltiplas (200) do campo de permeabilidade com dados parâmetros estatísticos (histograma e variograma) para representar a incerteza inicial no modelo de permeabilidade antes de

quaisquer dados de produção estarem disponíveis. Variáveis dinâmicas iniciais (ou seja, pressão inicial e saturações) são assumidas conhecidas, sem incerteza. Assim, as variáveis dinâmicas são as mesmas para cada realização. Se, todavia, variáveis iniciais são também incertas, elas devem ser representadas por meio de conjuntos. Simulação Gaussiana Sequencial é ainda descrita em Deutsch, CV. e Journel, A.G.: GSLIB: Geostatistical Software Library e User's Guide. 2ª edição, Imprensa da Universidade de Oxford, Nova Iorque, pp. 369, 1998.

•A etapa de previsão chama por um simulador de reservatório para executar simulação em avanço para cada uma das realizações até que o próximo ponto no tempo onde novas medições de dados de produção são disponíveis e devem ser assimiladas (por exemplo, t_{k+1}). O vetor de variável de estado depois de realizar a previsão é denotada por meio de $y^f_{k=1,j}$ (note os valores de variáveis estáticas m_s nas etapas inicial e de previsão são as mesmas). A previsão cria o conjunto de novos dados dinâmicos e de produção no dado tempo, consistentes com as variáveis iniciais estáticas. O ganho de Kalman pode então ser computado como:

$$G_k = C_{y,k}^f H_k^T (H_k C_{y,k}^f H_k^T + C_{d,k})^{-1} \quad (2)$$

onde G_k é o ganho de Kalman para o instante t_k . H_k é um Operador de matriz que relaciona o vetor de estado com os dados de produção. Visto que os dados de produção são parte do vetor de estado como na Eq. (1), H_k é na forma de $H_k = [0 \mid I]$, onde 0 é uma matriz $N_{d,k} \times (N_{y,k} - N_{d,k})$ com todos os zeros como suas entradas; I é uma matriz de identidade $N_{d,k} \times N_{d,k}$. O sobrescrito f denota previsão, significando que os valores são fornecidos a partir do simulador antes da atualização de filtro de Kalman. $C_{d,k}$ é a matriz de covariância de erro de dado de produção com dimensão de $N_{d,k} \times N_{d,k}$ e é diagonal uma vez que é assumido que os erros de dado de produção são independentes. $C_{y,k}^f$ é a matriz de covariância para as variáveis de estado no instante t_k que poderiam ser estimadas a partir do conjunto de resultados

previstos ($y_{k,j}^f$) usando um método estatístico padrão. A guisa de exemplo, e não de limitação, um tal método estatístico é provido por:

$$C_{y,t}^f = \frac{1}{N_e - 1} (Y_k^f - \bar{Y}_k^f)(Y_k^f - \bar{Y}_k^f)^T \quad (3)$$

onde Y_k^f é o conjunto de vetor de estado previsto no instante t_k com dimensão de $N_{y,k} \times N_e$ (N_e é o número de realizações no conjunto). $\bar{Y}_k^f$ é a média das variáveis de estado que é um vetor com dimensão de $N_{y,k}$. Aqueles versados na arte apreciarão que outros métodos estatísticos poderiam também ser usados e estão dentro do escopo desta invenção.

•Com G_k e dados de produção na etapa de tempo de assimilação (d_k), o vetor de variável de estado é então atualizado como:

$$y_{k,j}'' = y_{k,j}^f + G_k (d_{k,j} - H_k y_{k,j}^f) \quad (4)$$

Note que perturbações aleatórias são adicionadas aos dados de produção observados (d_k) para criar um conjunto de jogos de dados de produção com $d_{k,j}$ sendo o j -ésimo membro de conjunto. Burgers, G., van Leeuwen, P. J. e Evensen, G.: “Analysis scheme in the ensemble Kalman filter”, Monthly Weather Review, 126, 1719-1724, 1998, mostraram que a variabilidade entre os membros de conjunto atualizados é demasiadamente pequena se nenhum ruído aleatório é adicionado aos dados de produção. A Eq. (4) tem aparente significado físico: a segunda parte do segundo termo no lado à direita é a diferença de dados de produção simulados e observados quanto maior esta diferença, tanto maior será a atualização aplicada ao vetor de estado inicial. Se o dado de produção simulado em uma dada realização é igual ao dado observado, nenhuma atualização precisará ser feita neste modelo. A matriz de covariância depois da atualização pode ser computada como:

$$C_{y,t}'' = (I - K_k H_k) C_{y,t}^f \quad (5)$$

Com esta atualização, o vetor de estado de cada realização no conjunto é considerado para refletir os dados de produção mais correntes (d_k)

e a próxima etapa de tempo pode ser atingida, onde novos dados de produção são disponíveis para assimilação. As variáveis de estado são avançadas em tempo como:

$$y_{k,j}^f = F(y_{k-1,j}^u) \quad j = 1, 2, \dots, N_e \quad (6)$$

onde F é o simulador de reservatório. A partir das Eqs. (4) e (5), pode ser visto que a atualização do conjunto é linear e existe uma subjacente assunção que o erro de modelo e erro de dado de produção são independentes. Também, tanto os erros de dados de modelo quanto de dados de produção são não correlacionados em tempo.

O fluxo de trabalho total de EnKF é mostrado na figura 1 seguindo as setas sólidas. Os dados de produção são incorporados nos modelos de reservatório seqüencialmente em tempo quando eles se tornam disponíveis e o conjunto de modelos de reservatório estão evoluindo com o tempo representando a assimilação de medições no dado tempo. Quando novas medições de dados de produção são obtidas, é simples simular em avanço o fluxo usando o vetor de estado mais corrente para o tempo em que novos dados de produção são coletados e realizam a análise acima para atualizar o vetor de estado a fim de refletir os novos dados. Cada assimilação representa algum grau de incremento de qualidade na estimativa de modelo de reservatório. O grau deste incremento depende de quanta informação o novo dado medido está transportando. Assim, não existe necessidade de iniciar todo o processo novamente a partir do tempo de início original a fim de incorporar os novos dados obtidos, enquanto que, na tradicional correspondência de história, variáveis estáticas são tratadas como estáticas (não variando com o tempo) e todos dados de produção são colocados em correspondência simultaneamente usando um conjunto de variáveis estáticas. quando existem novas medições necessárias a serem colocadas em correspondência, toda a correspondência de história tem que ser repetida usando todos dados. A vantagem de usar EnKF é óbvia, especialmente, quando a freqüência de dados

é bastante alta, como, por exemplo, os dados a partir de sensores permanentes.

O EnKF pode ser integrado em qualquer simulador de reservatório porque ele somente requer as saídas do simulador. O simulador atua como uma caixa preta no processo de EnKF. Assim, a codificação do método EnKF é significativamente mais simples que tradicionais métodos de correspondência de história, baseados em gradiente, onde complicada codificação de cálculos de sensibilidade é requerida para diferentes simuladores e o acesso ao código de fonte do simulador é necessária. Uma outra vantagem de EnKF é que ele provê um conjunto de N_e modelos de reservatório, dos quais, todos, assimilam dados de produção atualizados com o tempo de computador de aproximadamente N_e simulações de fluxo (o tempo de CPU para assimilação de dado é muito pequeno em comparação com a simulação de fluxo). Isto é bem apropriado para análise de incerteza quando múltiplos modelos de reservatório são necessários. Com a tradicional correspondência de história, todavia, existe uma necessidade de repetir o processo de correspondência de história, intensivo em termos de CPU, com diferentes modelos iniciais para criar múltiplos modelos. Além disto, EnKF é bem apropriado para computação paralela/distribuição uma vez que a evolução de tempo de modelos de reservatório de conjunto é completamente independente.

O tradicional EnKF tem um problema potencial: as variáveis dinâmicas atualizadas m_d (por exemplo, pressão e saturações) usando a Eq. (4) podem não ser fisicamente significativas e podem ser inconsistentes com as variáveis estáticas atualizadas m_s (por exemplo, permeabilidade) do mesmo tempo. Por “inconsistentes” é entendido que as soluções das equações de fluxo usando um simulador de reservatório com base nas variáveis estáticas atualizadas são diferentes das variáveis dinâmicas atualizadas por meio do filtro. Isto é devido ao fato que a atualização de Kalman é linear, enquanto que as equações de fluxo são não lineares. Em um aspecto da presente

invenção, uma etapa adicional é adicionada ao EnKF, que deve ser referida como uma “etapa de conformação”, para assegurar que as variáveis dinâmicas e estáticas atualizadas são consistentes.

5 O método de atualização de EnKF utilizando a “etapa de conformação” é ilustrado na figura 1 com a etapa de conformação mostrada em setas tracejadas. Este método pode ser executado como segue:

(a) iniciando no instante t_k , o vetor de estado corrente $y_{k,j}$ (com variáveis estáticas e dinâmicas m_s e m_d) é usado para prever (simular em avanço) um vetor de estado previsto $y_{k,j}^f$ em um próximo instante t_{k+1} que
10 inclui variáveis estáticas e dinâmicas previstas m_s , m_d^f e um vetor previsto de produção d^f ; note que a variável estática m_s do vetor de estado previsto $y_{k,j}^f$
permanece inalterado a partir do tempo t_k enquanto as variáveis dinâmicas m_d^f são alteradas devido à computação de previsão;

(b) um ganho baseado no dado medido ou observado d e os
15 dados de produção previstos d^f , mais preferivelmente um ganho de Kalman G_k , é então computado utilizando o vetor de estado previsto $y_{k,j}^f$. Idealmente, o ganho de Kalman é calculado usando a Eq. (2);

(c) o ganho é então usado para criar um vetor de estado atualizado $y_{k,j}^u$ incluindo variáveis de estado m_s^u e m_d^u ; preferivelmente, esta
20 atualização do vetor de estado previsto $y_{k,j}^f$ utiliza a Eq. (4);

(d) as variáveis estáticas m_s^u da etapa (c) são então usadas para atualizar, ou seja, substituir, as variáveis estáticas m_s no vetor de estado original $y_{k,j}$ para criar um vetor de estado atualizado $y'_{k,j}$ incluindo as variáveis estáticas atualizadas m_s^u e as variáveis dinâmicas originais m_d ; e

25 (e) uma previsão de conformação é realizada, utilizando o vetor de estado atualizado $y'_{k,j}$ no instante t_k , para produzir vetor de estado conformado $y_{k,j}^c$ no instante t_{k+1} .

Este vetor de estado conformado $y_{k,j}^c$ no instante t_{k+1} é então usado para o início da próxima etapa de assimilação. Por meio de adição desta

etapa de conformação em uma convencional metodologia de atualização de conjunto de Kalman, é assegurado que as variáveis estáticas e dinâmicas atualizadas são consistentes com as equações de fluxo. O custo é uma duplicação do tempo de CPU em comparação com o EnKF tradicional de não conformação. Todavia, uma tal etapa de conformidade é, com frequência, desejável, e resultados aperfeiçoados são obtidos, particularmente para o tempo quando existem significantes variações nos dados de produção, por exemplo, quando novos poços são adicionados ou fechados.

O vetor de estado atualizado usando a Eq. (4) é a melhor estimativa linear equânime (a menor estimativa de variância). Assim, ela é uma atualização linear. A assunção subjacente de tal atualização é que os erros de vetor de estado e erros de observação são equânimes e não são correlacionados. Também, o vetor de estado atualizado ($y_{k,j}^u$) pode ser expresso como uma combinação linear de vetor de estado inicial ($y_{k,j}^f$) e vetor de observação (d_k) que minimiza a variância posterior. Uma assunção inerente em todos os filtros de Kalman é que os erros na etapa de análise são Gaussianos. Na prática, todavia, as equações de fluxo e dados medidos podem não satisfazer tais assunções.

Em um outro aspecto da presente invenção, uma proposta é introduzida para levar em conta a não-linearidade em um problema inverso geral através de uma iteração externa com uma atualização de atenuação. Este processo de iteração externa é introduzido na etapa de atualização de EnKF a fim de reduzir os efeitos de possíveis assunções incorretas (ver a figura 2). A atualização em cada iteração é como segue:

(a) partindo do instante corrente t_k , prever (simular em avanço) para o próximo instante (t_{k+1}) usando vetor de estado corrente ;

(b) computar o ganho de Kalman com base nos resultados de previsão resultantes (ou seja, usando a Eq. (2));

(c) atualizar somente o parâmetro estático (ou seja, usando

uma fórmula similar à Eq. (4)), mas com um fator de atenuação incluído;

$$y_{k,j}^{u,i+1} = y_{k,j}^{u,i} + \alpha_k^i G_k^i (d_{k,j}^i - H_k y_{k,j}^{f,i}) \quad (7)$$

onde

α_k^i é o parâmetro de atenuação no instante t_k na iteração i com valor entre 0 e 1;

5 $y_{k,j}^{u,i+1}$ = vetor de estado atualizado no instante t_k na iteração $i+1$;

$y_{k,j}^{u,i}$ = vetor de estado atualizado no instante t_k na iteração i ;

G_k^i = o ganho de Kalman na i -ésima iteração;

10 $d_{k,j}^i$ = dados de produção observados no instante t_k na i -ésima iteração;

H_k = Operador de matriz que se refere ao vetor de estado para dados de produção no vetor de estado no instante t_k ; e

$y_{k,j}^{f,i}$ = vetor de estado previsto no instante t_k na i -ésima iteração.

15 (d) tomar os novos parâmetros estáticos atualizados m_s (ou seja, permeabilidade e porosidade) e rodar a simulação de fluxo a partir do corrente (ou seja, t_k) para o próximo instante (t_{k+i}) novamente;

(e) computar uma função objetiva (média e variância de todos os membros) que é preferivelmente a raiz quadrada de diferença normalizada
20 entre os dados de produção observados e simulados; e

(f) se a média e variância da função objetiva não é menor que os valores pré-ajustados, retornar para a etapa a). Caso contrário, se a média e variância da função objetiva são suficientemente pequenas, ou quando a redução da função objetiva é demasiadamente pequena, prosseguir para a
25 próxima etapa de assimilação. Os novos parâmetros estáticos atualizados e as variáveis dinâmicas conformadas são usados como os vetores de partida/estado inicial para a próxima etapa de assimilação.

O parâmetro de atenuação " α_k^i " é mais preferivelmente selecionado por meio de um método de tentativas e erros para problemas diferentes. A guisa de exemplo, e não de limitação, este parâmetro de atenuação pode também ser escolhido como 0,5 como um valor de partida ou inicial. Aqueles versados na arte apreciarão que outros meios de selecionar o parâmetro de atenuação podem também ser selecionados e estão dentro do escopo da presente invenção.

As variáveis estáticas atualizadas são usadas para re-computar as variáveis dinâmicas atualizadas e dados de produção, a partir dos quais uma função objetiva é computada. A função objetiva representa a diferença entre os dados de produção observados e simulados. Como um exemplo, a função objetiva é computada como a raiz quadrada da diferença média entre os dados observados e simulados. A iteração é continuada até a função objetiva ser suficientemente pequena, ou seja, dentro de critérios predeterminados, ou quando a redução da função objetiva for suficientemente pequena. Tipicamente, estes critérios podem ser estabelecidos, a título de exemplo, em 10% do valor de função objetiva na etapa inicial ou etapa prévia.

Este processo de atualização iterativo será testado e é descrito abaixo usando um exemplo para ilustrar seu impacto sobre os resultados. Esta melhoria de iteração é necessária somente quando significantes alterações de comportamento de fluxo ocorrerem, tais como no começo do instante de produção ou quando novos poços são adicionados ou fechados. Para a maioria dos outros tempos de assimilação, iterações adicionais não são necessárias. O critério para se usar ou não usar estas iterações em cada tempo de assimilação pode ser ajustado e automaticamente aplicado durante o processo de assimilação. Além disto, para os casos quando a distância entre os valores simulados e medidos é grande, a tradicional atualização de EnKF pode causar problemas por causa da assunção linear. O uso de iterações adicionais pode reduzir os efeitos não-lineares e, assim, reduzir a divergência de filtro. A

divergência de filtro refere-se a um processo em que as variáveis estáticas atualizadas se desviam a partir dos valores verdadeiros ou valores estáveis previamente atualizados.

EnKF é um método de Monte-Carlo que se baseia no uso de um grande jogo de conjuntos para computar os dados estatísticos requeridos, bem como a incerteza derivada. A eficiência computacional de EnKF é, assim, grandemente dependente do tamanho de conjunto usado no cálculo. Resultados de tamanho de conjunto demasiadamente pequenos em grande erro de experimentação para computar as funções de covariância necessárias para a atualização de EnKF, e podem causar divergência de filtro. Estudos mostraram que um tamanho de conjunto relativamente grande é necessário para determinação confiável de incerteza de predição. Uma proposta para melhorar a eficiência de EnKF é melhorar a experimentação do membro inicial de modo que um menor número de membros pode prover extensão de incerteza tão grande quanto possível, resultando em atualização de filtro mais estável.

Métodos para experimentação de uma dada variável aleatória para eficiente cálculo de propagação de incerteza são disponíveis, tal como o método de expansão de caos polinomial ou método de colocação. Xiu, D., Karniadaskis, G. E.: “Modeling uncertainty in flow simulations via generalized polynomial chaos”, *Journal of Computational Physics*, 187, 137-167, 2003. A aplicação de tais métodos para encapsulação ótima de informação contida em um campo aleatório de entrada e variáveis de fluxo aleatórias de saída foi avaliada. Sarma, P., Durlofsky, L.J. , Aziz, K., e Chen, W.H.: “Efficient real-time reservoir management using adjoint-based optimal control and model updating”, apresentado à *Computational Geosciences*, 2005. Tais métodos requerem que as variáveis aleatórias sejam independentes, assim, uma metodologia de representação de uma função aleatória espacial correlacionada por meio de uma série de variáveis aleatórias

independentes é requerida, por exemplo, uma expansão de Karhunen-Loeve (L-K). Reynolds, A.C., He, N. Chu, L., e Oliver, D. S.: “Reparameterization techniques for generating reservoir descriptions conditioned to variogram e well-test pressure data”, SPE Journal, 1, 413-426, 1995. Este tipo de operação

5 é usualmente computacionalmente lento para um grande sistema porque ele chama convoca cálculo para valor próprio e vetor próprio.

Evensen, G.: “Sampling strategies e square root analysis schemes for the EnKF”, Ocean Dynamics 54, 539-560, 2004, propôs um algoritmo para re-experimentar um menor número de membros a partir do

10 original jogo de conjuntos maiores originais, de modo que os dados estáticos de experimentos, introduzidos por meio o grande jogo de conjuntos originais são mantidos. Foi mostrado que este método pode prover uma um maior espaço de incerteza que aquele a partir do mesmo número de membros de conjunto por meio de experimentação aleatória a partir do anterior pdf e pode

15 assegurar um estável comportamento de filtro. Dong, Y., Gu, Y. e Oliver, D. S.: “Quantitative use of 4D seismic data for reservoir description: the ensemble Kalman filter approach”, apresentado ao Journal of Petroleum Science & Engineering, 2005. Este método, todavia, requer a Decomposição de Valor Singular (SVD) que é computacionalmente intensiva para grandes

20 sistemas. Também o objetivo de re-experimentação é para a reprodução dos dados estatísticos providos por meio dos maiores membros de conjunto inicial. Assim, ela não leva em conta o espaço de incerteza dos dados de produção.

Uma proposta re-experimentação deve idealmente também

25 levar em conta o espaço de incerteza transposto pelas previsões de produção. Com este objetivo em mente, um simples esquema de re-experimentação pode ser usado, o qual é baseado na ordenação do grande jogo de conjunto original. A ordenação de modelo é baseada nas variáveis de produção mais variáveis. As seguintes etapas podem ser usadas:

(1) no instante inicial t_k , gerar um grande jogo de conjunto com tamanho de N_T ;

(2) simular em avanço cada modelo para o primeiro tempo de assimilação (t_{k+1});

5 (3) encontrar os dados de produção mais variáveis por meio de computação, por exemplo, o coeficiente de variação de cada dado de produção;

(4) ordenar o modelo de N_T com base nos dados de produção mais variáveis e registrar uma curva de função de distribuição cumulativa (cdf) com base na ordenação de cada modelo (ver a figura 3);

(5) experimentar um menor número de realizações (N_e) uniformemente a partir da curva de cdf para obter o modelo correspondente (ver a figura 3); e

15 (6) usar o menor tamanho de conjunto (N_e) para as etapas de assimilação que prosseguem.

Esta proposta é simples e fácil de ser implementada dentro de qualquer EnKF. Por meio da realização disto, alguns dos modelos iniciais que estão demasiadamente próximos uns dos outros em termos de suas respostas de produção são essencialmente eliminados. Também, dados de produção são

20 diretamente usados para a seleção dos modelos iniciais. O custo de tal processo é $N_T - N_e$ simulações de fluxo do tempo t_k para t_{k+i} . Uma desvantagem é que a experimentação é baseada em um dado de produção no primeiro tempo ou instante de assimilação e, assim, pode ser insuficiente para precisamente representar o espaço de incerteza para todo o modelo. Métodos

25 de ordenação mais sofisticados podem ser usados para melhorar a eficiência desta proposta. A título de exemplo, e não de limitação, estes métodos de ordenação poderiam incluir, por exemplo, simplificadas simulações de fluxo físicas ou simulação em uma grade de modelo mais grosseira.

EXAMPLES

A figura 4A mostra um campo de referência geoestatístico de 2-D (grade de 50x50x1 com tamanho de célula de 20 pés x 20 pés x 2 pés (6,1m x 6,1m x 6,1m)). O modelo é gerado usando o Método de Simulação Gaussiano Seqüencial. O $\ln(k)$ tem um histograma Gaussiano com média e variância de 6,0 e 3,0, respectivamente. A unidade de permeabilidade é mili-Darcy. O variograma é esférico com faixa de 200 pés (60,96 m) e 40 pés (12,2 m) na direção de 45 graus e 135 graus, respectivamente. É assumido de um poço de injeção (I) no centro do modelo com 4 poços de produção (P1 a P4) nos 4 cantos.

As características principais deste campo de referência são: (1) uma zona de alta permeabilidade e uma zona de baixa permeabilidade no centro do campo, (2) alta interconectividade entre poço I e poço P1, (3) baixa interconectividade entre poço I e poços P3 e P4. Este campo de referência é considerado como o modelo verdadeiro, e o objetivo é reconstruir modelos de reservatório, com base nos dados de produção em tempo real que são tão próximos ao campo verdadeiro quanto possível.

O reservatório é inicialmente saturado com petróleo com constante pressão inicial de 6000 psi (41,4 MPa) no topo. O poço de injeção tem taxa de injeção constante de 700 STB/dia com um controle de pressão de fundo de poço máxima (BHP) de 10000 psi (68,9 MPa). Todos os produtores estão produzindo um volume total constante de 200 STB/dia com controle de BHP mínimo de 4000 psi (27,6 MPa). A relação de mobilidade de água e petróleo é 10 e curvas de permeabilidade relativa quadrada padrão são usadas com saturação residual zero para petróleo e água. Compressibilidade e pressão capilar são ignoradas. Simulação de fluxo é feita até 720 dias e os resultados de BHP de cada poço, bem como taxas de produção de petróleo (OPR) e taxas de produção marinha (WPR) em poços de produção são mostradas nas figuras 4(B)-(D). Note a rápida ruptura de água de e a altas taxas de produção marinha no poço P1, enquanto que para P3, a ruptura de

água muito tardia com pequeno WPR e o BHP deste poço cai para um controle mínimo imediatamente após a produção, devido à baixa permeabilidade em torno deste poço bem como baixa conectividade entre este poço e o injetor.

5 O campo de permeabilidade de referência bem como os dados dinâmicos simulados (BHP, OPR e WPR) são considerados como verdadeiros e são assumidas que as medições de BHP, OPR e WPR em poços são disponíveis a cada 30 dias até 720 dias e eles são diretamente lidos a parti dos dados verdadeiros. Os desvios padrões de erros de medição são 3 psi (0,02 MPa), 1 STB, e 2 STB for BHP, OPR e WPR, respectivamente. Erros aleatórios Gaussianos são adicionados aos perfeitos dados de produção verdadeiros para criar um conjunto de dados ruidoso. Um vetor de perturbação com as mesmas variâncias como erros de medição é então adicionado aos dados ruidosos para criar um conjunto de dados de produção.

15 Um conjunto inicial de modelos de permeabilidade é gerado usando o método de Simulação Gaussiana Seqüencial com o mesmo histograma e variograma que o campo de referência. É assumido que não existe forte permeabilidade disponível, assim todos os modelos iniciais são incondicionais. Simulação condicional pode ser usada quando existem fortes ou suaves dados de permeabilidade e eles podem ser preservados durante a atualização de EnKF. Outros parâmetros (porosidade = 0,2, curvas de permeabilidade relativa, pressão inicial = 6000 psi (41,4 MPa), e saturações de água iniciais = 0,0) são assumidos conhecidos, sem incerteza. O conjunto de 200 modelos de permeabilidade iniciais é alimentado ao EnKF e são atualizados a cada 30 dias, assimilando os dados de produção observados (BHP, OPR, e WPR) em dados instantes.

Iteração vs. não-iteração.

As figuras 5(A)-(D) e 6(A)-(D) mostram as variações de dados de produção médios (BHP a P1 e WPR a P3) com o tempo e os associados

desvios padrões (ou seja, incerteza) a partir dos 200 modelos usando o tradicional EnKF (não-conformidade e não-iteração) e o proposto EnKF iterativo. Para o EnKF iterativo, um máximo de 5 iterações é usado com parâmetro de atenuação $\alpha = 0,5$. Pode ser visto no método tradicional EnKF, 5 que os dados de produção previstos no instante inicial são significativamente desviados a partir dos dados observados. Também, em cada tempo de assimilação, EnKF atualiza os dados previstos de volta para os dados observados com incerteza se reduzindo para quase zero. Quando cada vez mais dados são assimilados, os dados de predição estão indo cada vez para 10 mais próximos dos dados observados com incerteza cada vez menor. Assim, cada vez menos atualização é requerida para os modelos. Fenômeno similar é observado para EnKF, exceto que as predições no instante inicial são muito melhores e as incertezas são muito menores. Isto indica que os modelos atualizados por meio do EnKF iterativo pode prover predições mais acuradas 15 com menor incerteza quando da assimilação da mesma quantidade de dados, particularmente quando somente dados de instante inicial são assimilados.

Os campos de permeabilidade médios/mediados (isto é, a estimativa) e os campos de variância associados (incerteza) computados a partir do conjunto em 60 e 120 dias são dados nas figuras 7(A)-(D) e 8(A)-(D) 20 para EnKF não-iterativo e iterativo. Em comparação com o campo de referência na figura 4(A), pode ser visto que os resultados usando EnKF iterativo são ligeiramente melhores na captura das características de variação espacial do modelo de referência e os modelos resultantes têm menor incerteza.

25 Note que 5 iterações são alimentadas para cada atualização da etapa de EnKF. Neste exemplo, todavia, iterações são somente requeridas nas primeiras 3 etapas de assimilação (em 30, 60 e 90 dias) com o número de iteração atual de 5, 4, e 2, respectivamente. Depois da etapa 3, os dados de produção preditos são suficientemente próximos dos dados observados, de

modo que nenhuma iteração é requerida. As variações da função objetiva em cada iteração dentro das primeiras 3 etapas de assimilação são dadas nas figuras 9(A)-(C)). Note a significativa diminuição da função objetiva para a primeira etapa de assimilação (30 dias) indicando o impacto de iteração para o instante inicial quando respostas de fluxo têm fortes características não lineares e grandes atualização é necessária para o modelo para conjugar os dados de produção. Para os instantes futuros, a melhoria de conjugação de dados é menor.

As figuras 10(A)-(G) mostram os traçados dispersos de valores de permeabilidade em dois locais selecionados (célula (15, 15) e célula (45, 45) contando a partir do canto esquerdo inferior) dos 200 modelos de conjunto depois de cada iteração dentro da primeira etapa de assimilação (30 dias). Também mostrados são os correspondentes traçados dispersos de dados de produção (BHP e OPR para o poço P1). Pode ser visto que, inicialmente, a permeabilidade e dados de produção preditos são amplamente difundidos e centralizados nos locais errados, indicando grande incerteza e imprecisão nas previsões porque dados não são assimilados. Também, os dados de produção preditos, particularmente os BHP, não são normalmente distribuídos. Por meio da assimilação de dados de produção em 30 dias com o EnKF iterativo, ambos os valores de permeabilidade e dados de produção preditos estão gradualmente se movendo para os verdadeiros valores de modelo e os valores de produção observados de pois de cada iteração. No final da iteração, os dados de produção são estreitamente conjugados e valores de permeabilidade são dispersados em torno dos valores verdadeiros com pequena incerteza. Note que os dois locais selecionados estão em regiões importantes (entre os poços I e P1, entre I e P3) onde os valores de permeabilidade são criticamente importantes para conjugação de dados de produção. Por meio de assimilação dos primeiros dados em 30 dias, os valores de permeabilidade nestes dois locais podem ser bem identificados já com pequena incerteza. Isto permite

que uma precisa distribuição de permeabilidade seja obtida na última iteração. Menos precisão e maior incerteza seriam esperados em outros locais (ver as figuras 7-8).

Por outro lado, para o EnKF não-iterativo, modelos são atualizados somente uma vez usando a Eq. (4). Os traçados dispersos das permeabilidades atualizadas para os mesmos locais e os dados de produção preditos a partir do poço P1 são exibidos na figura 11. Pode ser visto que os modelos de permeabilidade atualizados, bem como os dados de produção preditos usando a atualização de uma etapa são menos precisos e sujeitos a maior incerteza em comparação com o método iterativo EnKF proposto. Os dados de produção computados a partir dos modelos atualizados ainda exibem fortes características não-Gaussianas.

A seguir, a capacidade predita dos modelos atualizados por meio do EnKF tradicional e iterativo é comparada. Assentamentos de predição são realizadas em 720 dias usando todos dos 200 modelos depois de assimilação de dados em 60 e 120 dias usando os dois métodos. As figuras 12(A)-(D) mostram as predições de dados de produção (média e desvio padrão de BHP em P1 e WPR atem3) a partir dos 200 modelos atualizados em 60 dias, enquanto que as figuras 13(A)-(D) exibem as predições usando modelos atualizados em 120 dias. De ambas as figuras, pode ser visto que as predições usando os modelos atualizados por meio do EnKF iterativo são, ambos, mais precisos e têm menos incerteza em comparação com os modelos atualizados por meio do EnKF não-iterativo. Assim, as otimizações de reservatório em tempo real com base nas predições dos modelos atualizados por meio do EnKF iterativo é provável que produzam melhores estratégias para realizar mais potencial de produção. Para ambos os métodos, predições mais precisas e com menos incerteza são obtidas quando mais dados de produção são assimilados.

Redução de Tamanho e Conjunto Via Re-experimentação

A efetividade do simples método de re-experimento proposto para reduzir o tamanho de conjunto em EnKF será agora demonstrado. 200 modelos iniciais ($N_T = 200$) são usados e são rodados em avanço/predição de 0 a 30 dias. Com base nos dados de produção (BHP, OPR e WPR) em 30 dias, a variável que mais varia é identificada como o BHP no poço P1. Estes 200 modelos iniciais são ordenados com base no BHP em P1, do menor valor para o maior valor, resultando em função de distribuição cumulativa (cdf), como mostrado nas figuras 14(A)-(F). Note que o menor BHP em P1 é do membro de modelo 6 onde valores de permeabilidade em torno de P1 são baixos, enquanto o máximo BHP em P1 é do membro de modelo 183 onde P1 é posicionado em uma região de alta permeabilidade que é bem conectada com o injetor. A partir dos 200 modelos iniciais, 50 membros são experimentados usando método de experimento uniforme com base no cdf, ou seja, com intervalo de $\text{cdf}=0,02$. Claramente, os 50 modelos resultantes podem representar o mesmo espaço de incerteza em termos do BHP no poço P1 que os originais 200 modelos. Muitos modelos com respostas de fluxo que estão demasiadamente próximas umas das outras foram eliminados.

Os 50 modelos re-experimentados são então usados para prosseguir a atualização de EnKF. Para comparação, a atualização de EnKF é realizada usando os primeiros 50 modelos dos iniciais 200 modelos, representando os 50 membros iniciais aleatoriamente experimentados. O EnKF é então usado com a etapa de conformação somente para atualizar os modelos que assimilam os mesmos dados de produção, como mostrado na figura 4. Com base nos modelos de permeabilidade atualizados na última etapa de tempo (720 dias) usando os diferentes jogos de conjuntos iniciais, as simulações de fluxo são rodadas para toda a história de produção usando todos os modelos atualizados. As figuras 15(A)-(F) mostram o BHP para os poços P1 e P4 usando três diferentes jogos de conjuntos iniciais: 200 membros aleatórios, 50 membros aleatórios, e 50 membros re-experimentados

a partir dos 200 membros aleatórios. Os histogramas de BHP em P1 em 720 dias são exibidos na figura 16. Destas duas figuras, pode ser visto que:

(1) 200 membros de conjunto aleatoriamente experimentados parecem ser suficientes para prover razoáveis previsões e incerteza associada;

(2) 50 membros aleatoriamente experimentados não são suficientes, resultando em previsões imprecisas (dados de produção observados são estão fora do envoltório de previsões); e

(3) usando dos 50 modelos iniciais re-experimentados dos 200 membros aleatórios, as previsões são tanto mais precisas (média de previsões próxima à observação) quanto mais acuradas (menos extensão) em comparação com o uso de 50 membros aleatórios. Isto claramente demonstra a efetividade da abordagem da re-experimentação proposta para reduzir o tamanho de conjunto.

Efeito de intervalo de tempo de assimilação

O intervalo de tempo entre as duas etapas de assimilação de EnKF é também uma consequência importante para a aplicação prática de EnKF. Em geral, a assimilação é necessária todas as vezes que significante alterações de comportamento de fluxo ocorrem, tais como adição de novos poços no sistema de reservatório, conversão de poço, ou fechamento de poço. Dados de produção poderiam ser observados em diferente frequência e permanentes sensores obter dados em frequência muito elevada. De acordo com a teoria de EnKF, é preferível que o tempo de assimilação em um intervalo não seja demasiadamente pequeno ou demasiadamente grande. Dados de produção podem ser redundantes e correlacionados, e, assim, nenhuma nova informação pode ser absorvida quando os pontos selecionados estão demasiadamente próximos, observados no tempo. Por outro lado, se intervalo de tempo de assimilação é demasiadamente grande, os parâmetros de modelo e dados de produção podem ser altamente não lineares, causando problemas na atualização de filtro, tal como divergência de filtro.

A fim de investigar o impacto do uso de diferentes tamanhos de intervalo de tempo de assimilação, EnKF é usado para atualizar 200 modelos de reservatório que assimilam dados de produção em diferentes intervalos de tempo (30, 60, 100 e 300 dias). Tanto os métodos não-iterativos quanto iterativos de EnKF são usados. As figuras 17(A)-(B) e 18(A)-(B) mostram a média e variância resultantes dos 200 modelos atualizados em 300 dias usando o EnKF não-iterativo e iterativo. As previsões de desempenhos de poço de 300 dias a 720 dias usando o modelos atualizados em 300 dias são dadas nas figuras 19(A)-(B) e 20(A)-(B). A partir destas figuras, pode ser visto que:

(1) quando pequenos intervalos de tempo (por exemplo, 30 ou 60 dias) são usados, os modelos atualizados e a incerteza associada, bem como as previsões que usam estes modelos são muitos similares se ou não a interação é usada na atualização de EnKF;

(2) quando maiores intervalos de tempo (por exemplo, 100 ou 300 dias) são usados, vemos significativa diferença entre os resultados usando o EnKF iterativo e aqueles usando o EnKF não-iterativo. Os modelos atualizados usando o EnKF iterativo são visualmente melhores que aqueles atualizados por meio do EnKF não-iterativo. As previsões que usam modelos atualizados por meio do EnKF não-iterativo são sujeitas a incerteza muito maior que aquela do EnKF iterativo. Isto novamente demonstra que os modelos atualizados por meio do EnKF iterativo provê mais acuradas previsões com menos incerteza; e

(3) de forma mais importante, com o EnKF não-iterativo, a qualidade dos modelos atualizados e as previsões exibem significativa diferença quando diferentes intervalos de tempo de assimilação são usados (ver as figuras 17 e 19). Não obstante, a diferença em qualidade usando diferentes intervalos de tempo são muito menores com o EnKF iterativo.

Modelos atualizados por meio do uso do EnKF não-iterativo

não provêm confiavelmente boas previsões quando o intervalo de tempo de assimilação é grande. Não obstante, modelos confiáveis podem ainda ser obtidos com o EnKF iterativo. Embora não se deseje ser restrito a uma teoria particular, isto pode ser devido ao fato de que o uso de iteração em EnKF
5 pode estabilizar o processo de atualização e corrigir a não-linearidade.

Finalmente, o processo de atualização de permeabilidade e dados de produção durante a primeira etapa de tempo de assimilação usando intervalo de tempo de 300 dias é mostrado. A figura 21 (fileira superior) mostra os traçados dispersos de valores de permeabilidade iniciais em dois
10 locais, bem como os dados de produção preditos (BHP e OPR no poço P1) em 300 dias a partir dos 200 modelos iniciais. Pode ser visto que o modelo inicial e variáveis de produção são significativamente diferentes dos valores verdadeiros e observados com grande incerteza. A distribuição de dados de produção, particularmente for BHP, exibe características não-Gaussianas.

Usando uma etapa de tempo de assimilação de 300 dias, a figura 21 (a partir da segunda fileira para a fileira inferior) exibe os traçados dispersos de valores de permeabilidade atualizados, bem como os dados de produção preditos em diferentes iterações para o primeiro tempo de assimilação usando o EnKF iterativo. De forma clara, os valores de
15 permeabilidade são gradualmente movidos em direção aos valores verdadeiros com os dados de produção preditos indo para mais próximos dos valores observados. No final da iteração, excelentes valores de permeabilidade e previsões de produção são obtidos, os quais são muito similares aos resultados mostrados na figura 10. Isto novamente demonstra a
20 robustez do EnKF iterativo, ou seja, acurada atualização e boa conjugação de dados de produção podem ser obtidos até mesmo com um grande intervalo de tempo de assimilação. A iteração dentro da atualização de EnKF servem como um processo de correção para a não-linearidade e não-Gaussianidade.

Como uma comparação, usando o EnKF não-iterativo, a

permeabilidade atualizada, e os dados de produção preditos com base nos modelos atualizados são dados nas figuras 22(A)-(B). Em comparação com os modelos iniciais, os valores de permeabilidade atualizada são movidos para mais próximos de seus valores verdadeiros, resultando em predições
5 melhoradas. Todavia, as permeabilidades atualizadas são ainda sujeitas a grande incerteza, resultando em deficiente conjugação de dados de produção preditos para os dados observados, devido ao uso de grande intervalo de tempo de assimilação (300 dias). Estes resultados não são tão bons quanto os resultados do uso de menor intervalo de tempo, mostrado na figura 11 que
10 indica a sensibilidade de uso de diferente tamanho de intervalo de tempo para o EnKF não-iterativo.

EnKF tradicional e conformante para contínua atualização de modelos de reservatório para assimilar dados de produção em tempo real foram revisados. Um processo de iteração foi introduzido durante a
15 atualização de EnKF para levar ainda em conta a não-linearidade e não-Gaussianidade no sistema. Um simples e uniforme esquema de re-experimentação é introduzido para reduzir o tamanho de conjunto. Este esquema de re-experimentação usa a informação de ordenação dos dados de produção mais variáveis computados na primeira etapa de assimilação para
20 assegurar que os pequenos membros de conjunto selecionados tenham o mesmo espaço de incerteza em termos dos dados de produção selecionados que o grande jogo de conjuntos inicial. A sensibilidade de uso de diferente intervalo de tempo de assimilação é também investigado.

Do exemplo acima, as seguintes conclusões podem ser tiradas:

25 (1) o EnKF é eficiente e robusto para atualização de reservatório em tempo real para assimilar dados de produção atualizados;

(2) o tradicional EnKF não-iterativo, sendo afetado por meio das características não-lineares e não Gaussianas no reservatório e sistema de fluxo, pode prover atualização não precisa. Também, os resultados são

sensíveis ao tamanho do intervalo de tempo de assimilação; e

(3) por meio da introdução da iteração dentro do processo de atualização de EnKF, modelos mais acurados são obtidos com menor incerteza, resultando em melhor conjugação de dados produção e mais acuradas previsões. Também, o processo de atualização de filtro se torna mais estável.

(4) iteração é necessária somente em instante inicial ou quando de significantes alterações de comportamento de fluxo, por exemplo, quando da adição de poços ou fechamento de poço. Estes são os instantes quando o sistema exibe características fortemente não-lineares.

(5) o proposto esquema de re-experimentação é simples, fácil de ser implementado, ainda muito eficiente. Ele leva em conta o comportamento de fluxo que é uma diferença principal com relação aos outros métodos.

Nomenclaturas

C_d = Covariância de erro de dado de produção

C_y = Matriz de covariância de vetor de estado

$C_{m,l}$ = Elemento em C_y

d = Vetor de dado de produção

F = Simulador de fluxo à frente

G = Ganho de Kalman

H = Operador de matriz que refere-se ao vetor de estado para dados de produção no vetor de estado

I = Matriz de identidade

$\ln(k)$ = Logaritmo natural de permeabilidade

m_s = Variáveis estáticas

m_d = Variáveis dinâmicas

N = Número total de células ativas no modelo de reservatório

N_d = Dimensão de vetor de dado de produção

N_e = Número de realizações no conjunto

N_T = Número de realizações no conjunto inicial

N_y = Dimensão de vetor de estado t = Tempo

Y = Conjunto de vetor de estado

5 $\bar{Y}_k^f$ = média do vetor de estado

y - Vetor de estado

Subscrito

k = Índice de tempo

j = Índice de membro de conjunto

10 Sobrescrito

f = Previsão

i = Índice de Iteração

T = Transposição

u = Atualizado

REIVINDICAÇÕES

1. Método para atualizar um conjunto de modelos de reservatório para refletir os dados de produção medidos mais correntes e para precisamente prever desempenho de reservatório, caracterizado pelo fato de
5 que compreende:

(a) gerar um conjunto de modelos de reservatório, o conjunto sendo representado, em uma primeira etapa de tempo, por meio de um vetor de estado inicial de variáveis de estado estáticas e dinâmicas;

10 (b) da primeira etapa de tempo para uma segunda etapa de tempo, prever em avanço o vetor de estado inicial para computar um vetor de estado previsto que inclui variáveis estáticas e dinâmicas de previsão e dados de produção de previsão;

(c) computar um ganho com base nas variáveis de estado estáticas e dinâmicas atualizadas;

15 (d) computar um vetor de estado atualizado utilizando o ganho computado da etapa (c), bem como dados de produção observados e os dados de produção de previsão;

20 (e) criar um vetor de estado de conformidade incluindo as variáveis de estado estático atualizadas da etapa (d) e as variáveis dinâmicas de estado da etapa (b); e

(f) da primeira etapa de tempo para a segunda etapa de tempo, prever em avanço o vetor de estado de conformidade para computar um vetor de estado de conformidade previsto que inclui variáveis de estado estáticas e dinâmicas previstas;

25 pelo que o conjunto de modelos de reservatório é atualizado com as variáveis de estado estáticas e dinâmicas do vetor de estado de conformidade previsto estando em conformidade um com o outro.

2. Método de acordo com a reivindicação 1, caracterizado pelo fato de que:

as variáveis de estado estático incluem pelo menos uma de permeabilidade e porosidade.

3. Método de acordo com a reivindicação 1, caracterizado pelo fato de que:

5 as variáveis dinâmicas de estado incluem pelo menos uma de pressão e saturação.

4. Método de acordo com a reivindicação 1, caracterizado pelo fato de que:

o ganho é um ganho de Kalman.

10 5. Método de acordo com a reivindicação 4, caracterizado pelo fato de que:

o ganho de Kalman é computado em conformação com o uso da seguinte expressão matemática:

$$G_k = C_{y,k}^f H_k^T (H_k C_{y,k}^f H_k^T + C_{d,k})^{-1}$$

onde

15 G_k = o ganho de Kalman para o instante t_k ;

$C_{u,k}^f$ = a matriz de covariância de vetor de estado;

H_k = o operador de matriz que se refere ao vetor de estado para dados de produção no vetor de estado; e

$C_{d,k}$ = a covariância de erro de dado de produção medido.

20 6. Método de acordo com a reivindicação 1, caracterizado pelo fato de que:

a etapa de computar o vetor de estado atualizado comporta com o uso do seguinte:

$$y_{k,j}^u = y_{k,j}^f + G_k (d_{k,j} - H_k y_{k,j}^f)$$

y_{kj}^u = vetor de estado atualizado no instante t_k ;

25 G_k = o ganho de Kalman;

$D_{k,j}$ = dados de produção observados no instante t_k ;

$H_k y_{kj}^f$ = dados de produção previstos.

7. Método de acordo com a reivindicação 1, caracterizado pelo fato de que:

a computação do vetor de estado atualizado inclui o uso de uma função de atenuação.

5 8. Método de acordo com a reivindicação 1, caracterizado pelo fato de que compreende:

computar uma função de objeção com base nos dados de produção observados e previstos e substituir o vetor de estado inicial pelo vetor de estado de conformidade; e etapas de iteração (b)-(f) utilizando uma
10 função de atenuação até a função objetiva estar dentro de um critério predeterminado.

9. Método de acordo com a reivindicação 8, caracterizado pelo fato de que:

a função de atenuação comporta com a expressão matemática:

$$y_{k,j}^{u,i+1} = y_{k,j}^{u,i} + \alpha_k^i G_k^i (d_{k,j}^i - H_k y_{k,j}^{f,i})$$

15 onde

α_k^i é o parâmetro de atenuação no instante t_k na iteração i com valor entre 0 e 1;

$y_{k,j}^{u,j+1}$ = vetor de estado atualizado no instante t_k na iteração i
+1;

20 $y_{k,j}^{u,i}$ = vetor de estado atualizado no instante t_k na iteração i ;

G_k^i = o ganho de Kalman na i -ésima iteração;

$D_{k,j}^i$ = dados de produção observados no instante t_k na i -ésima iteração;

25 H_k = Operador de matriz que se refere ao vetor de estado para dados de produção no vetor de estado no instante t_k ; e

$F_{k,j}^{f,i}$ = vetor de estado previsto no instante t_k na i -ésima iteração.

10. Método de acordo com a reivindicação 6, caracterizado

pelo fato de que ainda compreende a etapa de:

computar uma função objetiva representativa da diferença entre os dados de produção medidos e previstos.

5 11. Método de acordo com a reivindicação 10, caracterizado pelo fato de que:

a função objetiva é com base na média e variância de todos os membros.

12. Método de acordo com a reivindicação 10, caracterizado pelo fato de que ainda compreende a etapa de:

10 (f) etapas de iteração (b) -(f) até que a média e variância da função objetiva seja menor que um determinado critério de terminação.

13. Método para assimilar dados em um conjunto de modelos, caracterizado pelo fato de que compreende:

15 (a) em um instante inicial t_0 , gerar um conjunto de modelos com tamanho de N_T ,

(b) simular em avanço cada modelo para um primeiro instante de assimilação (t_1);

(c) determinar os dados de produção mais variáveis;

20 (d) ordenar os N_T modelos com base nos dados de produção mais variáveis;

(e) criar uma curva de função de distribuição cumulativa (cdf) com base na ordenação de cada modelo;

25 (f) experimentar um menor número de realizações (N_e) uniformemente a partir da curva cdf para obter o correspondente número de modelo;

(g) reduzir o tamanho de conjunto de N_T para N_e ; e

(h) usando o menor tamanho de conjunto (N_e) para as etapas de assimilação que prosseguem.

14. Método de acordo com a reivindicação 12, caracterizado

pelo fato de que:

etapa (c) de determinar os dados de produção mais variáveis é computada usando o coeficiente de variação de cada dado de produção.

15. Dispositivo de armazenamento de programa, caracterizado
5 pelo fato de ser legível por uma máquina, tangivelmente incorporando um programa de instruções executáveis pela máquina para executar etapas de método para atualizar um conjunto de modelos de reservatório, conduzir uma simulação de reservatório, ditas etapas de método compreendendo:

10 (a) gerar um conjunto de modelos de reservatório, o conjunto sendo representado, em uma primeira etapa de tempo, por meio de um vetor de estado inicial de variáveis de estado estáticas e dinâmicas;

(b) da primeira etapa de tempo para uma segunda etapa de tempo, prever em avanço o vetor de estado inicial para computar um vetor de estado previsto que inclui variáveis estáticas e dinâmicas de previsão e dados
15 de produção de previsão;

(c) computar um ganho com base no vetor de estado previsto e nos dados de produção de previsão;

(d) computar um vetor de estado atualizado de variáveis de estado estáticas e dinâmicas atualizadas utilizando o ganho computado da
20 etapa (c), e os dados de produção observados e previstos;

(e) criar um vetor de estado de conformidade incluindo as variáveis de estado estático atualizadas da etapa (d) e as variáveis dinâmicas de estado da etapa (b); e

25 (f) da primeira etapa de tempo para a segunda etapa de tempo, prever em avanço o vetor de estado de conformidade para computar um vetor de estado de conformidade previsto que inclui variáveis de estado estáticas e dinâmicas previstas;

pelo que o conjunto de modelos de reservatório é atualizado com as variáveis de estado estáticas e dinâmicas do vetor de estado de

conformidade previsto estando em conformidade um com o outro.

16. Aparelho de simulação para atualizar um conjunto de modelos de reservatório, caracterizado pelo fato de ser adaptado para solucionar um sistema de equações não lineares que representam uma entidade particular, dito aparelho de simulação gerando um conjunto de resultados de simulação quando dito sistema de equações não lineares é solucionado, dito conjunto de resultados de simulação incluindo um ou mais parâmetros que caracterizam dita entidade particular compreendendo:

(a) um meio para gerar um conjunto de modelos de reservatório, o conjunto sendo representado, em uma primeira etapa de tempo, por meio de um vetor de estado inicial de variáveis de estado estáticas e dinâmicas;

(b) um meio para prever em avanço o vetor de estado inicial para computar um vetor de estado previsto, da primeira etapa de tempo para uma segunda etapa de tempo, que inclui variáveis estáticas e dinâmicas de previsão e dados de produção de previsão;

(c) um meio para computar um ganho com base no vetor de estado previsto e nos dados de produção de previsão;

(d) um meio para computar um vetor de estado atualizado de variáveis de estado estáticas e dinâmicas atualizadas utilizando o ganho computado da etapa (c) e os dados de produção observados e previstos;

(e) um meio para criar a vetor de estado de conformidade incluindo as variáveis de estado estático atualizadas da etapa (d) e as variáveis dinâmicas de estado da etapa (b); e

(f) um meio para prever em avanço o vetor de estado de conformidade para computar um vetor de estado de conformidade previsto, da primeira etapa de tempo para a segunda etapa de tempo, que inclui variáveis de estado estáticas e dinâmicas previstas;

pelo que o conjunto de modelos de reservatório é atualizado

com as variáveis de estado estáticas e dinâmicas do vetor de estado de conformidade previsto estando em conformidade um com o outro.




FIG. 1




FIG. 2




FIG. 3




FIG. 4A




FIG. 4B




FIG. 4C




FIG. 4D

BHP no poço P1: Média




FIG. 5A

BHP no Poço P1: Desv. Padr.




FIG. 5B

WPR no Poço P3: Média




FIG. 5C

WPR no Poço P3: Desv. Padr.




FIG. 5D

BHP no Poço P1: Média




FIG. 6A

BHP no Poço P1: Desv. Padr.




FIG. 6B

WPR no Poço P3: Média




FIG. 6C

WPR no Poço P3: Desv. Padr.




FIG. 6D

Média em 60 dias




FIG. 7A

Variância em 60 dias




FIG. 7B

Média em 120 dias




FIG. 7C

Variância em 120 dias





FIG. 7D



Média em 60 dias




FIG. 8A

Variância em 60 dias




FIG. 8B

Média em 120 dias




FIG. 8C

Variância em 120 dias






FIG. 8D






FIG. 9A




FIG. 9B










FIG. 9C






FIG. 10G




FIG. 10H




FIG. 11A




FIG. 11B




FIG. 12A




FIG. 12B




FIG. 12C




FIG. 12D




FIG. 13A




FIG. 13B




FIG. 13C




FIG. 13D










FIG. 14






FIG. 16A




FIG. 16B




FIG. 16C

Média:Delta (t)=30 dias




FIG. 17A

Variância:Delta (t)=30 dias




FIG. 17B

Média:Delta (t)=60 dias




FIG. 17C

Variância:Delta (t)=60 dias




FIG. 17D

Média:Delta (t)=100 dias




FIG. 17E

Variância:Delta (t)=100 dias




FIG. 17F

Média:Delta (t)=300 dias





FIG. 17G

Variância:Delta (t)=300 dias





FIG. 17H

Média:Delta (t)=30 dias




FIG. 18A

Variância:Delta (t)=30 dias




FIG. 18B

Média:Delta (t)=60 dias




FIG. 18C

Variância:Delta (t)=60 dias




FIG. 18D

Média:Delta (t)=100 dias




FIG. 18E

Variância:Delta (t)=100 dias




FIG. 18F

Média:Delta (t)=300 dias




FIG. 18G

Variância:Delta (t)=300 dias




FIG. 18H




FIG. 19A




FIG. 19B




FIG. 19C




FIG. 19D




FIG. 19E




FIG. 19F




FIG. 19G












FIG. 19H






FIG. 21A




FIG. 21B




FIG. 21C




FIG. 21D




FIG. 21E




FIG. 21F




FIG. 21G




FIG. 21H




FIG. 22A




FIG. 22B

RESUMO

“MÉTODOS PARA ATUALIZAR UM CONJUNTO DE MODELOS DE RESERVATÓRIO E PARA ASSIMILAR DADOS EM UM CONJUNTO DE MODELOS, DISPOSITIVO DE ARMAZENAMENTO DE PROGRAMA E APARELHO DE SIMULAÇÃO PARA ATUALIZAR UM
5 CONJUNTO DE MODELOS DE RESERVATÓRIO”

Um método, sistema e aparelho para atualização de modelo de reservatório em tempo real usando conjunto de filtros de Kalman são descritos. O método inclui uma etapa de conformidade para colocar variáveis de estado estáticas e dinâmicas em conformidade umas com as outras durante
10 uma etapa de tempo da atualização. Também, um método de atenuação iterativo é usado em conjunção com a etapa de conformidade para levar em conta características não Gaussianas e não lineares em um sistema. Também, um método de re-experimento é descrito, que reduz o tamanho de conjunto de
15 modelos de reservatório que devem ser atualizados.