

ABORDAGENS PARA ATUALIZAÇÃO DE PARÂMETROS NO CONTEXTO DE ESTIMAÇÃO DUAL DE ESTADOS E PARÂMETROS

PETRUS E. O. G. B. ABREU*, BRUNO O. S. TEIXEIRA*, ALEXANDRE R. MESQUITA*

**Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais (UFMG)
Av. Antônio Carlos, 6627 - 31270-901, Belo Horizonte, Minas Gerais, Brasil*

Emails: petrusabreu@ufmg.br, brunoot@ufmg.br, amesquita12@ufmg.br

Abstract— This paper addresses the problem of dual parameter-and-state estimation for systems with intermittent input excitation. Two approaches are investigated. The first approach is recursive and uses least squares with time-varying forgetting factor. The second approach uses batch least squares in moving data windows whenever a transient is detected in such data. Both approaches are tested in the composition of a soft sensor for downhole pressure in oil wells.

Keywords— Dual state-and-parameter estimation, transient detection, recursive least squares with time-varying forgetting factor.

Resumo— Este artigo estuda o problema de estimação dual de estados e parâmetros de sistemas com excitação intermitente. Duas abordagens são investigadas para a etapa de estimação de parâmetros. A primeira abordagem é recursiva e usa algoritmos de mínimos quadrados com fator de esquecimento variante no tempo. A segunda usa algoritmos em batelada em janelas de dados móveis quando transientes são detectados nos dados. Ambas as abordagens são testadas na composição de sensores virtuais de pressão de fundo de poços de extração de petróleo.

Palavras-chave— Estimação dual de estados e parâmetros, detecção de transientes, mínimos quadrados recursivos com fator de esquecimento variável.

1 Introdução

A partir de dados de entrada e saída e de modelos no espaço de estados, é possível estimar os estados de sistemas dinâmicos usando algoritmos de estimação de estados. Em alguns casos, alguns dos parâmetros desses modelos são desconhecidos ou variam com o tempo de forma que devem ser estimados concomitantemente aos estados. Para tratar do problema de estimação de estados e parâmetros de sistemas dinâmicos, a literatura apresenta duas formulações: a conjunta e a dual. A primeira trata a estimação de ambos em uma única etapa, por meio da definição de um vetor de estados aumentado que inclui os parâmetros. Na segunda, o modelo de processo e de evolução dos parâmetros são tratados separadamente em dois estimadores distintos. Segundo (Nelson, 2000), a abordagem dual atenua alguns problemas de divergência que ocorrem na conjunta, por meio do desacoplamento entre a estimação dos estados e parâmetros. Neste trabalho, escolhe-se a formulação dual para tratar o problema supracitado.

Diversas aplicações de engenharia justificam o estudo do referido problema. Especificamente, este trabalho é motivado pelo desenvolvimento de sensores virtuais de pressão de fundo de poços de petróleo (Eck et al., 1999). Considerando a metodologia apresentada em (Teixeira et al., 2014) para o desenvolvimento desses sensores virtuais, têm-se duas etapas. A primeira etapa da metodologia corresponde à identificação do sistema, para a qual são obtidos modelos de processo e de observação. Na segunda etapa, esses modelos são usados para compor um filtro de Kalman (estimador

de estados) ou um banco de filtros. Todavia, é difícil encontrar modelos para tal sistema que expliquem o comportamento do mesmo em diferentes pontos de operação e que considere o efeito de envelhecimento dos poços. Considerando o cenário no qual somente dados históricos de operação do processo estão disponíveis para obtenção de modelos, é razoável optar pela obtenção de modelos de estrutura mais simples (por exemplo, linear) e considerar a possibilidade de ajustar os parâmetros desses modelos ao longo do tempo. Neste caso, configura-se um problema de estimação dual de estados e parâmetros. Em (Proença, 2015; Teixeira et al., 2016), são obtidos resultados preliminares para esse problema. Para tal um esquema que emprega um filtro de Kalman para estimação de estados seguido de um algoritmo de mínimos quadrados recursivo para estimação de parâmetros é usado; veja Figura 1(a). Todavia, o fato de não haver sempre persistência de excitação nos dados compromete o desempenho dos modelos continuamente atualizados. Segundo (Lotufo, 2010), esses algoritmos podem passar por problemas de estouro da matriz de covariância, levando à sua divergência, quando se tem um sinal de entrada sem persistência de excitação.

Este trabalho investiga duas abordagens para se atualizar os parâmetros do modelo do sistema. Na primeira abordagem, utiliza-se um algoritmo recursivo de mínimos quadrados com fator de ponderação variável (Beza e Bongiorno, 2014) a fim de, automaticamente, priorizar os dados contendo transientes que favoreçam à estimação dos parâmetros. Na segunda abordagem, é usada uma técnica para detecção de transientes (Ribeiro e

Aguirre, 2015) em janela de dados m veis. Assim, as janelas s o avaliadas em tempo de execu  o, para determinar se a mesma possui informa  o din mica relevante para estima  o. Somente para as janelas para as quais detecta-se um transiente, estimam-se os par metros.

2 Formula  o do Problema

Considere o sistema din mico a tempo discreto

$$x_k = f(x_{k-1}, u_{k-1}^f, \theta_{k-1}, w_{k-1}), \quad (1)$$

$$y_k = h(x_k, u_k^h, v_k), \quad (2)$$

em que $f : \mathbb{R}^n \times \mathbb{R}^{p_f} \times \mathbb{R}^{n_\theta} \times \mathbb{R}^q \rightarrow \mathbb{R}^n$   o modelo de processo e $h : \mathbb{R}^n \times \mathbb{R}^{p_h} \times \mathbb{R}^r \rightarrow \mathbb{R}^m$   o modelo de observa  o, $x_k \in \mathbb{R}^n$   o vetor de estados, $y_k \in \mathbb{R}^m$   a sa da medida, $u_k = [u_{k-1}^f \ T \ u_k^h \ T]^T \in \mathbb{R}^{p_f+p_h}$   a entrada assumidamente conhecida, $w_{k-1} \in \mathbb{R}^q$ e $v_k \in \mathbb{R}^r$ s o os ru dos de processo e medi  o, respectivamente, e $\theta_{k-1} \in \mathbb{R}^{n_\theta}$   o vetor de par metros. Assume-se que θ_k satisfa a ao modelo de regress o linear

$$z_k = \psi_{k-1}^T \theta_k + e_k, \quad (3)$$

em que $z_k \in \mathbb{R}$ e $\psi_{k-1} \in \mathbb{R}^{n_\theta}$ s o a sa da e regressores do modelos, os quais s o dados por valores presente e passados de x_k e u_{k-1}^f , e e_k   o erro de modelagem.

Pelo uso dos modelos de processo e observa  o, projetam-se estimadores baseados no filtro de Kalman para a predic  o dos estados $\hat{x}_k$. A fim de tratar o caso no qual o modelo de processo   variante no tempo, utilizam-se aqui t cnicas para estima  o de estados e par metros. Cumpre esclarecer que a extens o para o caso de ambos os modelos variantes no tempo   direta.

Neste trabalho, emprega-se a abordagem de estima  o dual de estados e par metros. A ideia est  em usar das estimativa do filtro $\hat{x}_k$ e das entradas u_{k-1}^f , para estima  o dos par metros $\hat{\theta}_k$ do modelo de processo por meio de alguma t cnica de estima  o de par metros que se considere apropriada. Dessa maneira, esses modelos s o atualizados em tempo de execu  o de forma independente e desacoplada em rela  o a estimativa do filtro.

3 Metodologia

Duas abordagens para atualiza  o dos par metros $\hat{\theta}_k$ s o tratadas neste trabalho. A primeira usa m nimos quadrados recursivos com fator de esquecimento vari vel; veja Figura 1(a). A segunda emprega um estimador de par metros em batelada para a etapa de estima  o de par metros; veja Figura 1(b). Para tal, realiza-se uma detec  o de transientes em uma janela de dados m vel, de modo a determinar se essa ser  ou n o usada para atualiza  o dos par metros.




Figura 1: (a) Abordagem 1 para estima  o recursiva de par metros. Primeiramente tem-se que o filtro de Kalman (FK)   atualizado com as estimativas de par metros $\hat{\theta}_{k-1}$ do instante anterior. Em seguida, o FK utiliza u_k , y_k , e $\hat{x}_{k-1}$ para estimar $\hat{x}_k$. Pelo uso de $\hat{x}_k$ e u_k , o algoritmo MQR estima os par metros $\hat{\theta}_k$ para atualiza  o do modelo de processo que ser  usado no instante seguinte.

(b) Abordagem 2 para estima  o em batelada de par metros. Em cada intervalo de busca, estuda-se a janela m vel de dados (JM) armazenada no *buffer* Dados. Caso essa atenda aos requisitos de detec  o de transientes (DT), a estima  o dos par metros para atualiza  o do modelo de processo do filtro em estudo   realizada.

3.1 Estimador Recursivo de Par metros

Nesta abordagem, s o utilizados algoritmos recursivos com pondera  o vari vel. Essa pondera  o   comumente realizada pelo ajuste do fator de esquecimento (FE) em cada itera  o k . Na Figura 1(a), apresenta-se um diagrama esquem tico dessa abordagem. Primeiramente, tem-se que a entrada u_k e a observa  o y_k s o aplicadas ao FK, o qual estima os estados $\hat{x}_k$ do sistema no instante k . Para tal, os estados $\hat{x}_{k-1}$ e par metros $\hat{\theta}_{k-1}$ estimados no instante $k-1$ s o usados. De forma desacoplada, o filtro interage com o algoritmo de m nimos quadrados recursivos com pondera  o vari vel, MQR- λ_k , de modo a atualizar seu modelo de processo pela estima  o de seus par metros $\hat{\theta}_k$. Assim, o filtro   atualizado para uso na pr xima itera  o $k+1$.

O algoritmo recursivo escolhido para estudo   descrito em (Beza e Bongiorno, 2014), o qual trata do uso de um FE vari vel como m todo de pondera  o dos dados. Esse algoritmo   designado aqui como FEV. Nesse algoritmo, os valores de m ximo λ_{ss} e m nimo λ_{tr} do FE s o determinados *a priori*. Quando um transiente   detectado, por uma repentina mudan a na entrada, calcula-se o erro de predic  o resultante d_k . Assim, caso esse erro seja superior a um limiar pr -definido d_{th} , o FE recebe o valor m nimo e retorna gradativamente para o m ximo seguindo uma exponencial amortecida. FEV   dado pelas equa  es

$$K_k = \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k + \lambda_k}, \quad (4)$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k[z_k - \psi_k^T \hat{\theta}_{k-1}], \quad (5)$$

$$P_k = \frac{1}{\lambda_k} \left(P_{k-1} - \frac{P_{k-1} \psi_k \psi_k^T P_{k-1}}{\psi_k^T P_{k-1} \psi_k + \lambda_k} \right), \quad (6)$$

em que K_k é o ganho de Kalman, P_k é a matriz de covariância, ψ_k é o vetor de regressores, $\hat{\theta}_k$ é o vetor de parâmetros estimados, z_k é a saída do modelo de regressão linear e λ_k é o FE variante. A forma de atualização do FE é dada por

$$\lambda_k = \begin{cases} \lambda_{tr}, & \text{se } |d_k| > d_{th} \\ \lambda_{ss} - (\lambda_{ss} - \lambda_{tr})e^{-k/\tau_{hp}}, & \text{caso contrário.} \end{cases} \quad (7)$$

As configurações atribuídas para esse algoritmo correspondem as variáveis: $\lambda_{ss}=0,9999$, $\lambda_{tr}=0,95$, $d_{th}=0,073$ e $\tau_{hp}=4$ é a constante de tempo de transição entre os FE projetados.

Para fins de comparação, também é considerado algoritmo com FE constante, descrito em (Aguirre, 2015) e designado aqui como MQR com FE constante ajustado para $\lambda=0,9999$. Esse é um caso especial do FEV, quando não se detecta mudança repentina na entrada, em que λ_k é constante para todo k .

3.2 Estimador em Batelada com Detecção de Transientes

Na segunda abordagem, utiliza-se o algoritmo de mínimos quadrados em batelada (MQ) para estimação de parâmetros considerando janelas móveis de dados (JM). A motivação para esse método está na não-garantia de haver persistência de excitação nos dados coletados. Em processos industriais, por exemplo, tal condição configura operação normal do processo. Assim, é usada uma técnica para detecção de transientes na janela de dados, determinando se a mesma é apropriada ou não para identificação, de modo a habilitar ou descartar essa para uso na estimação dos parâmetros.

A Figura 1(b) mostra o diagrama representativo dessa abordagem. Para o filtro em estudo, tem-se que a cada iteração k se estimam os estados $\hat{x}_k$ usando para tal os sinais de entrada u_k , da saída y_k e dos estados estimados a uma amostra de instante anterior $\hat{x}_{k-1}$. Durante as iterações do algoritmo, o campo determinado por Dados armazena os sinais da entrada do modelo de processo u_{k-1}^f e dos estados estimados $\hat{x}_k$. Esses compõem a matriz de regressores (MR). Quando esse conjunto de dados alcança um tamanho especificado como adequado para análise, faz-se a detecção de transiente (DT). Isso se repete entre intervalos para as novas JM. Para cada uma que atenda aos requisitos de excitação pré-determinados, é habilitada a estimação por meio do MQ, e a matriz de regressores é usada para estimação. Esse estudo das janelas de dados é realizado em tempo de execução. Quando uma janela que é classificada como detentora de dados dinâmicos com transiente é detectada, a atualização dos parâmetros do modelo de processo é realizada usando dados de

tal janela. Para estimação dos parâmetros tem-se o algoritmo MQ com condição inicial dado como

$$\hat{\theta} = [\Psi^T \Psi + P_0^{-1}]^{-1} [\Psi^T Z + P_0^{-1} \theta_0],$$

em que $\Psi \in \mathbb{R}^{N \times n_\theta}$ é a MR, θ_0 é a última estimativa para os parâmetros, P_0 é a matriz de covariância dessa estimativa, e Z é o vetor de N medições da saída. Para cálculo da incerteza nos parâmetros tem-se, $P_0 \approx (\Psi^T \Psi)^{-1} \sigma_e^2$, em que $\sigma_e^2 = \xi^T \xi / (N - n_\theta)$, com o vetor de resíduos $\xi = Z - \psi \hat{\theta}$ (Aguirre, 2015). Para o MQ convencional, tem-se que $\theta_0 = 0$ e $P_0 = 0$.

A técnica de detecção de transientes usada neste artigo é baseada no método *offline* proposto por (Ribeiro e Aguirre, 2015). É realizada aqui uma adaptação de tal método, para se trabalhar com detecção de janelas de forma *online*.

3.2.1 Técnica de Detecção de Transientes

A ideia base para essa técnica possui dois passos, conforme apresentado na Figura 2. O primeiro trata da análise de persistência de excitação na JM, enquanto o segundo passo verifica se há correlação desses dados com as entradas do modelo.

No primeiro passo, avalia-se a persistência de excitação nos dados por meio de regressões do sinal de interesse $\hat{x}_k$ (saída de (1)), ajustando-se assim um modelo auto-regressivo (AR) para tal sinal. Considere o modelo linear AR $\hat{x}_k = a_1 \hat{x}_{k-1} + a_2 \hat{x}_{k-2} + \dots + a_n \hat{x}_{k-n}$, em que $\{a_1, a_2, \dots, a_n\}$ são parâmetros a serem estimados. Se o sinal $\hat{x}_k$ é conhecido no intervalo $k=1, \dots, N$, em que N refere-se ao tamanho da JM, reescrevendo na forma matricial, tem-se $A\hat{b}=\hat{x}$, sendo

$$A = \begin{bmatrix} \hat{x}_0 & \hat{x}_{-1} & \dots & \hat{x}_{-n+1} \\ \hat{x}_1 & \hat{x}_0 & \dots & \hat{x}_{-n+2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{x}_{N-1} & \hat{x}_{N-2} & \dots & \hat{x}_{N-n} \end{bmatrix}, \hat{x} = \begin{bmatrix} \hat{x}_1 \\ \hat{x}_2 \\ \vdots \\ \hat{x}_N \end{bmatrix}, \hat{b} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix},$$

em que $A \in \mathbb{R}^{N \times n}$ é a matriz de regressão, $\hat{b} \in \mathbb{R}^n$ é o vetor de parâmetros e $\hat{x} \in \mathbb{R}^N$ é o vetor da JM.

Dessa maneira, ao procurar solucionar essa equação matricial, tem-se o ponto chave para o estudo da persistência nos dados, uma vez que o posto da matriz A corresponde ao limite máximo de parâmetros $\hat{b}$ que se consegue estimar com essa JM. Por sua vez, o posto está relacionado com a quantidade de informação contida no sinal. O método usado para estimar o posto r_2^{ef} da matriz A é definido como $r_2^{ef} = \sum_{i=2}^n H[(\sigma_{i-1} - \sigma_i) - l_2]$, em que

H refere-se a função de Heaviside, que retorna 1 se o argumento em estudo não é negativo e 0 se é




Figura 2: Diagrama simplificado da técnica de detecção de transientes. Este diagrama detalha o bloco DT mostrado na Figura 1(b).

negativo. Essa estimativa é baseada na diferença de valores singulares próximos $(\sigma_i - \sigma_{i-1})$, que é comparada por um valor limitante l_2 . Assim, se a diferença for maior que esse limite, considera-se que os valores singulares em análise são distintos. Caso a estimativa r_2^{ef} atenda às especificações pré-determinadas, o segundo passo é realizado.

O segundo passo tem como finalidade avaliar o índice de correlação (IC) s entre a janela de dados e cada um das p entradas do modelo. Sua formulação é dada por $s = \sum_{\tau=-\tau_{\max}}^{\tau_{\max}} g(\rho(\tau), \tau, l)$, em que $\tau_{\max}$ é o máximo atraso de interesse e $g(\rho(\tau), \tau, l)$ é definido como:

$$g(\rho(\tau), \tau, l) = \begin{cases} 0, & \text{se } |\rho(\tau)| \leq l, \\ \frac{|\rho(\tau)| - l}{|\tau|}, & \text{se } |\rho(\tau)| > l \text{ e } \tau \neq 0, \\ |\rho(\tau)| - l, & \text{se } |\rho(\tau)| > l \text{ e } \tau = 0, \end{cases}$$

em que $\rho(\tau)$ é a função de correlação cruzada normalizada e $l = \frac{1.96}{\sqrt{N}}$ é o intervalo de confiança de 95%, sendo N o tamanho da janela em amostras.

Dessa maneira, as JM que atenderem ambas as propriedades são usadas para a estimação dos parâmetros do modelo pelo algoritmo de mínimos quadrados em batelada MQ.

Para o algoritmo DT são utilizadas as seguintes configurações: $r_2^{ef}=9$, $s_1>1$ e $s_2>0,5$. O tamanho da JM é de 2000 amostras e o intervalo de pesquisa entre janelas de 500 amostras.

4 Resultados Experimentais

Considere o processo de extração de petróleo em águas profundas (Teixeira et al., 2014), representado na Figura 3, para o qual desenvolvem-se sensores virtuais para estimação da pressão de fundo de poço.

O processo é resumido como a seguir. Gás pressurizado flui através da tubulação de *gas lift* na direção da plataforma (tag 4) rumo à árvore de natal no leito marinho com uma vazão (FT4), onde ele é injetado na saída do reservatório. A densidade do fluido é então reduzida tal que a pressão no reservatório torna-se alta o suficiente para transportar a mistura de petróleo, gás e água até a plataforma. No leito marinho, um conjunto de válvulas chamadas de árvore de natal molhada (PT2 e TT2) regulam o fluxo de produção do leito à plataforma. Na plataforma, uma válvula do tipo SDV (PT3a) pode interromper a produção durante uma situação de emergência e a válvula de choke de produção (PT3 e TT3) regula a taxa de produção na plataforma. Diferentes regimes dinâmicos de fluxo são atingidos dependendo dos valores das válvulas de *gas lift* (PT4 e PT4a) e pressão de fundo do poço (PT1).

(Proença, 2015; Teixeira et al., 2016) propõem modelos matemáticos para o projeto de sensores virtuais para o processo supracitado. Esses modelos foram identificados na representação ARX

polinomial (do inglês, *AutoRegressive with eXogenous inputs*), a qual pode ser escrita no formato (3). Em seguida, pares de modelos foram reescritos como (1)-(2) e usados no FK.

Para as análises aqui propostas, escolheu-se estudar o poço R tratado em (Proença, 2015; Teixeira et al., 2016). Para obter (1), usa-se um modelo cuja saída z_k é dada pela pressão de fundo de poço PT1 e é dado por

$$z_k = 1,5634 z_{k-1} - 0,5715 z_{k-2} + 0,1174 u_{1,k-1} - 0,0696 u_{1,k-2} - 0,0176 u_{1,k-5} - 0,0502 u_{1,k-7} + 0,0158 u_{1,k-9} - 0,000038 u_{2,k-7} + 0,8482 \quad (8)$$

em que $u_{1,k}$ e $u_{2,k}$ são respectivamente a TT3 e FT4. Para (2), tem-se um modelo cuja saída z_k é dada pela pressão a montante da válvula choke de produção PT3. Em (Proença, 2015; Teixeira et al., 2016), observou-se a importância de atualizar os parâmetros de (8) ao longo do tempo enquanto a pressão de fundo de poço é estimada.

4.1 Estudo das Abordagens 1 e 2

Inicialmente considera-se o caso em que se estima apenas um parâmetro do modelo de processo, referente ao primeiro atraso da saída z_{k-1} , para o modelo (8). Essa escolha deve-se à grande importância desse regressor ao se explicar a saída z_k . Na Figura 4, são apresentadas as estimativas resultantes e a evolução dos parâmetros das janelas selecionadas para estudo.

Para uma melhor análise das estimativas, escolheram-se duas janelas de dados menores, com 7000 amostras aproximadamente 5 dias de coleta, numeradas como 1 e 2 e delimitadas pelas linhas verticais na Figura 4(a). A primeira refere-se à uma transição no ponto de operação, Figura 4(b). Já a segunda, é o cenário em que o sinal permanece num mesmo patamar, sem transiente, Figura 4(c). As variações resultantes no parâmetro para cada uma das janelas é apresentado nas Figuras




Figura 3: Diagrama P&ID de um poço de petróleo com *gas lift*, em que TT, PT e FT são os transmissores de temperatura, pressão e vazão. Os números 1 (fundo de poço) e 2 (árvore de natal molhada) representam variáveis no leito marinho, enquanto 3 (produção) e 4 (*gas lift*) tratam variáveis da plataforma. A direção do fluxo é 4-1-2-3. As variáveis do fundo do poço são medidas próximas à saída do reservatório. Fonte: (Teixeira et al., 2014).




Figura 4: Estimativas para a pressão de fundo de poço, considerando cada um dos algoritmos propostos para a etapa de atualização do modelo de processo. (a) algoritmos FEV, MQR e DT-MQ, estimando a massa de dados total referente à aproximadamente 7 meses; (b) janela de dados 1; (c) janela de dados 2; (d) e (e) evolução do parâmetro estimado para as janelas 1 e 2, respectivamente. As linhas verticais (--) indicam os intervalos selecionados para análise.

4(d)-(e), as quais sofrem alterações na casa decimal de 10^{-4} e 10^{-3} , respectivamente.

Para o primeiro cenário, Figura 4(b), é possível notar que o algoritmo DT-MQ teve resultados mais satisfatórios quando comparado com os demais, obtendo uma estimativa mais aproximada do valor verdadeiro. Isso pode ser explicado, devido a detecção de transientes ocasionarem mudanças pontuais no parâmetro do modelo, Figura 4(d). Assim, a atualização é adequadamente aplicada conforme tem-se informação relevante nos dados, por exemplo, na amostra de 96000, em que é perceptível pelo fato da ocorrência de mudança no patamar. Considerando o intervalo a partir da amostra de 100000, Figura 4(d), em que não detecta-se transientes, o parâmetro mantém-se constante para o DT-MQ. Porém, permanece variando para os algoritmos recursivos, tornando-os mais propícios à gerar degradação do modelo, fazendo com que o DT-MQ se sobressaia.

No segundo cenário, Figura 4(c), no qual não há transientes, o parâmetro mantém-se constante para o DT-MQ, como esperado. Para o algoritmo FEV teve-se resultados muito próximos do DT-MQ, e mais satisfatórios que o MQR. Isso é possivelmente explicado, pelo fato dos algoritmos recursivos com FE variante conterem maior conhecimento dinâmico do sistema durante o instante em que há excitação nos dados, janelas anteriores. Assim, para essa janela em que os dados não revelam transiente, esses algoritmos sofrem menor degradação.

4.2 Avaliação das estimativas resultantes

Avalia-se o desempenho relativo dos métodos investigados por meio do índice de erro percentual absoluto médio (EPAM), $EPAM = \frac{1}{N} \sum_{k=1}^N \frac{|y_k - \hat{y}_k|}{|y_k|}$, em que y_k é a saída medida, $\hat{y}_k$ é a saída estimada e N é o tamanho da janela de dados.

Os cenários considerados para avaliação são apresentados nas Figuras 4(b)-(c), referidas respectivamente como Janela 1 e 2. Para essas, também foram desenvolvidas a análise em que se realiza a estimação de todos os parâmetros do modelo de processo. Nesse caso, a fim de amenizar as variações nos parâmetros na abordagem 2, usa-se do algoritmo de MQ com condição inicial, o qual restringe as correções com base na incerteza estimada dos parâmetros anteriores.

Tabela 1: Avaliação das estimativas resultantes da pressão de fundo do poço R pelo método EPAM. Considerando os algoritmos de atualização propostos.

Algoritmos	Índice EPAM			
	estimando um parâm.		estimando todos os parâm.	
	Janela 1	Janela 2	Janela 1	Janela 2
MQR	2,79	13,60	13,02	7,21
FEV	2,68	8,67	36,24	19,05
DT-MQ	1,87	8,51	2,17	9,24

Para o caso de se estimar um parâmetro, percebe-se que o algoritmo DT-MQ produziu os melhores resultados; veja Tabela 1. Comparado ao MQR com FE constante, observa-se que o FEV

produziu melhores resultados. No caso da janela 1, pode-se considerar, como explicação, o fato do sinal em estudo ser variante e carregar certa informação sobre o sistema. Assim, esse algoritmo gera uma maior atualização do parâmetro, em momentos adequados. Esse mesmo motivo pode ser usado para explicar o fato de que, na janela 2, o FEV também foi melhor que o MQR. Para esse último cenário, não havia transiente nos dados.

Para o caso em que se estima todos os parâmetros, considerando como base o algoritmo em batelada com condição inicial para o DT-MQ, manteve-se superior aos demais na janela 1. Para a janela 2, o MQR produziu resultado um pouco melhor. Observe que o FEV piorou quando passou a se estimar todos os parâmetros, pois ampliaram-se os graus de liberdade para atualização do modelo. Como notado, para o DT-MQ, devido a falta de transiente nos dados, os parâmetros são mantidos constantes, sendo isso mostrado em parte pela Figura 4(e). Assim, pode-se considerar que a última atualização do modelo, por esse algoritmo, não capturou de modo adequado a dinâmica implícita nos dados.

5 Conclusões

Neste trabalho, estudou-se o problema de estimação dual de estados e parâmetros. Duas abordagens para a etapa de atualização de parâmetros foram investigadas. Considerou-se o cenário em que os estados são estimados por um filtro de Kalman, e tem-se interesse em atualizar o modelo de processo do mesmo pelo uso dessas abordagens.

A diferenciação entre as abordagens foi estabelecida pelo tipo de algoritmo utilizado: métodos recursivos ou em batelada para janelas móveis. Para o primeiro, os parâmetros são atualizados a cada iteração mas com ponderação variável a fim de considerar o cenário no qual os dados têm pouca persistência de excitação. O segundo método faz uso de uma técnica para detecção de transientes nas janelas, para as quais estimam-se os parâmetros em batelada. Em teoria, o segundo método proporciona menor degradação do modelo pois só atualiza os parâmetros quando detecta-se transiente nos dados.

Os resultados obtidos reafirmaram as expectativas iniciais. Ou seja, a segunda abordagem produziu estimativas de parâmetros que melhoraram a estimativa da pressão de fundo de poço (estado). Para aplicações *online* para as quais não se pode garantir que os dados sempre tenham persistência de excitação, a abordagem baseada em detecção de transiente para janelas móveis parece ser a mais indicada.

Foram testados dois cenários de estimação dos parâmetros. No primeiro, apenas um parâmetro (relacionado ao regressor mais importante) foi estimado, ao passo que no segundo todos parâme-

tros são atualizados. Para a abordagem recursiva, observou-se que o primeiro cenário é uma escolha mais segura. Afinal, como os parâmetros são sempre estimados, a possibilidade de estimar todos quando houver pouca persistência de excitação degrada o poder de predição do modelo. Para a abordagem com detecção de transientes, esse problema não ocorre. Nesse caso, ao usar um algoritmo em batelada com estimativa inicial igual à última estimativa de parâmetros, foram obtidos resultados parecidos com aqueles produzidos quando apenas um parâmetro era estimado.

Como proposta para trabalhos futuros, torna-se interessante determinar algum método que especifique os limiares para as variáveis de configuração da técnica de detecção de transientes automaticamente em tempo de execução.

Agradecimentos

O presente trabalho foi realizado com o apoio financeiro da Petrobras, CAPES-Brasil, FAPEMIG e CNPq.

Referências

- Aguirre, L. A. (2015). *Introdução à Identificação de Sistemas: Técnicas Lineares e Não-Lineares: Teoria e Aplicação*, 4 ed, Belo Horizonte: Editora UFMG.
- Beza, M. e Bongiorno, M. (2014). Application of recursive least squares algorithm with variable forgetting factor for frequency component estimation in a generic input signal, *IEEE Transactions on Industry Applications* **50**(2): 1168–1176.
- Eck, J., Ewherido, U., Mohammed, J. e et. al (1999). Downhole Monitoring: The Story So Far. *Oilfield Review*, **11**(4): 20–33.
- Lotufo, F. A. (2010). *Desenvolvimento de um sensor virtual para processos não-lineares e variantes no tempo, com aplicação em planta de neutralização de pH*, Tese de doutorado em Engenharia Mecânica, Universidade Estadual Paulista (UNESP).
- Nelson, A. T. (2000). *Nonlinear estimation and modeling of noisy time-series by dual Kalman filtering methods*, PhD thesis, Archive.
- Proença, L. B. (2015). Modelagem Matemática para Projeto de Sensores Virtuais de Pressão de Fundo de Poços de Petróleo. *Monografia de Graduação em Engenharia de Controle e Automação*, Universidade Federal de Minas Gerais.
- Ribeiro, A. e Aguirre, L. A. (2015). Selecting transients automatically for the identification of models for an oil well *2nd IFAC Workshop on Automatic Control in Offshore Oil and Gas Production*, Florianópolis, Brasil, 154–158.
- Teixeira, B. O. S., Proença, L. B. e Campos, M. C. M. (2016). Modelagem Matemática para Projeto de Sensores Virtuais de Pressão de Fundo de Poços de Petróleo. *XXI Congresso Brasileiro de Automática*, Vitória, Brasil, submetido.
- Teixeira, B. O. S., Castro, W. S., Teixeira, A. F. e Aguirre, L. A. (2014). Data-driven soft sensor of downhole pressure for a gas-lift oil well. *Control Engineering Practice*, **22**(1): 34–43.