

ESTIMAÇÃO RECURSIVA DE PARÂMETROS VARIANTES NO TEMPO PARA SISTEMAS COM SINAL DE ENTRADA COM EXCITAÇÃO INTERMITENTE

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 work compares recursive algorithms for time-varying parameter estimation. Least-squares-based algorithms with variable weighting factor are analyzed under the influence of different scenarios of the input signal, where the persistence of excitation changes with time. As a means of evaluating algorithms, tests are performed both in simulated and experimental systems. For the former, we use a mass spring system, for which the time-varying spring constant must be estimated. For the experimental case, the problem of obtaining models for soft sensors for downhole pressure of oil extraction processes is addressed.

Keywords— Time-varying parameter estimation, Recursive algorithms with variable weighting factor, Intermittent excitation.

Resumo— Este trabalho compara algoritmos recursivos para estimação de parâmetros variantes no tempo. Algoritmos baseados nos mínimos quadrados com ponderação variável são analisados sob influência de diferentes cenários do sinal de entrada, em que a persistência de excitação muda com o tempo. Como meio de avaliação dos algoritmos, testes são realizados tanto em um sistema simulado quanto experimental. Para esse primeiro é usado um sistema massa mola amortecedor, para o qual se deseja estimar a constante elástica da mola, que é variante. Como exemplo experimental, tem-se o problema de obter modelos usado em sensores virtuais de estimação da pressão de fundo para processos de extração de petróleo.

Palavras-chave— Estimação de parâmetros variantes, Algoritmos recursivos com ponderação variável, Persistência de excitação intermitente.

1 Introdução

O campo de identificação de sistemas visa a estudar métodos para determinação de modelos matemáticos que sejam capazes de explicar o comportamento dinâmico implícito em dados de entrada e saída, referentes a um determinado sistema (Ljung, 1997). Por isso, faz-se necessário que os dados coletados para identificação possuam informação dinâmica relevante. Essa característica é obtida, quando possível, por meio do projeto de testes dinâmicos adequados para o sistema.

Quando se trabalha com sistemas lineares, o projeto do sinal de testes, tem por objetivo excitar uma ampla faixa de frequências do sistema, gerando uma saída com informação dinâmica significativa. Um sinal de simples implementação prática e que produz bons resultados é o sinal binário pseudoaleatório (PRBS do inglês, *pseudo random binary signal*), que pode ser adaptado para testes em sistemas não lineares, por meio da variação de sua amplitude (Aguirre, 2015).

Para estimação de parâmetros invariantes no tempo, para processamento *online*, os algoritmos de mínimos quadrados recursivos (MQR) são vastamente usados. Já para o caso de parâmetros variantes, modificações desse algoritmo podem ser propostas. Essas modificações se resumem em propor métodos de adaptativamente ponderar cada nova observação do processo (Aguirre, 2015).

Dentre esses algoritmos modificados, tem-se o MQR com fator de esquecimento (FE) constante, o qual possui maior capacidade de adaptação à

variação de parâmetros. Porém, esse pode passar por problemas de estouro da matriz de covariância, que ocorre quando se tem um sinal de entrada sem persistência de excitação (Lotufo, 2010).

Com base nessa dificuldade é que este artigo objetiva estudar métodos de estimação com ponderação variável, considerando diferentes cenários da persistência de excitação do sinal de entrada aplicado ao sistema a ser analisado. Com isso, deseja-se analisar o desempenho dos estimadores para dados com informação dinâmica intermitente. Esses podem ocorrer com frequência na identificação de sistemas cujos sinais de entradas não podem ser projetados, como é o caso do uso de dados históricos na identificação de modelos ou aplicações em tempo real.

Os algoritmos estudados neste trabalho podem ser classificados em três diferentes grupos de acordo com a forma de ponderação dos dados: (i) FE constante, (ii) FE variante, e (iii) ponderação do tamanho do passo de correção (TPC). O primeiro método é clássico, designado aqui como C-MQR (convencional MQR). Para o grupo (ii), têm-se os trabalhos de (Paleologu et al., 2008), (Beza e Bongiorno, 2014) e (Bhotto e Antoniou, 2013), designados respectivamente como, CRR-FE (FE controlado pela relação com o ruído), RRPA-FE (FE reajustado pela resposta de um filtro passa-altas) e CEPSP-FE (FE controlado pelo erro a *posteriori* sem ruído). O terceiro e último método, é descrito em (Vega et al., 2009), e designado como MC-FE (FE determinado por um mecanismo de chaveamento).

2 Formula  o do Problema

Considere o modelo din mico do sistema dado por

$$y_k = \psi_{yu,k-1}^T \theta_k + v_k, \quad (1)$$

em que $y_k \in \mathbb{R}$   a sa da do sistema no instante $k \in \mathbb{N}$, $\psi_{yu,k-1} \in \mathbb{R}^{n_\theta}$ corresponde aos regressores formados por combina  es lineares ou n o-lineares da sa da $y_{k-1}, \dots, y_{k-n_y}$, e/ou entrada(s) $u_{1,k}, \dots, u_{1,k-n_{u1}}, u_{q,k}, \dots, u_{q,k-n_{uq}}$, $\theta_k \in \mathbb{R}^{n_\theta}$ s o os par metros de ajuste e v_k   o erro de modelagem.

Para se realizar a identifica  o do sistema, assume-se que os dados din micos $\{y_k, u_{1,k}, \dots, u_{q,k}\}$, em $k=1, \dots, N$, s o conhecidos. Com isso, deseja-se estimar os par metros θ_k para que o modelo din mico explique a din mica dominante subjacente a esse conjunto de dados.

Considerando que se esteja identificando um sistema a par metros variantes, procurando ajustar os mesmos para o modelo din mico, definimos a classe de algoritmos MQR com FE vari vel, cuja formula  o geral   dada por

$$K_k = g_k \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k + \lambda_k}, \quad (2)$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k [y_k - \psi_k^T \hat{\theta}_{k-1}], \quad (3)$$

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

sendo $0 \ll \lambda_k < 1$ o FE e $0 \leq g_k \leq 1$ o TPC. T m-se que K_k   o ganho de Kalman e P_k a matriz de covari ncia. Para o algoritmo C-MQR, λ_k   constante e o $g_k=1$ para todo k .

Como mencionado, uma dificuldade encontrada pelo C-MQR ocorre quando o sinal de entrada n o   persistentemente excitante, podendo com o passar do tempo k levar ao estouro da matriz de covari ncia P_k e   diverg ncia do algoritmo.

Dessa maneira, a an lise de estimadores que ponderem os dados de forma vari vel torna-se uma alternativa valiosa. Essa pondera  o resume-se em atualizar o λ_k ou o g_k a cada instante de tempo k , estimando os par metros em tempo de execu  o.

3 M todos Recursivos de Estima  o de Par metros Variantes no Tempo

Para os estudos aqui desenvolvidos s o analisados 4 algoritmos recursivos com pondera  o vari vel, os quais prop em formas de atualiza  o do FE ou TPC. A principal ideia abordada por esses algoritmos concentra-se na melhoria da capacidade de rastreabilidade de transientes e redu  o da varia  o do erro em estado estacion rio.

3.1 Algoritmo CRR-FE

O controle para determina  o do FE para esse algoritmo, (Paleologu et al., 2008), baseia-se na estimativa do ru do que est  relacionado com o sinal de erro ap s converg ncia para a solu  o verdadeira. Dessa forma, caso a condi  o $\hat{\sigma}_{e,k} \leq \gamma \hat{\sigma}_{v,k}$,

com $1 < \gamma \leq 2$, seja atendida, faz-se $\lambda_k = \lambda_{\max}$. Caso contr rio, o FE pode ser avaliado como

$$\lambda_k = \min \left(\frac{\hat{\sigma}_{q,k} \hat{\sigma}_{v,k}}{\epsilon + |\hat{\sigma}_{e,k} - \hat{\sigma}_{v,k}|}, \lambda_{\max} \right), \quad (5)$$

em que usamos estimativas dos desvios padr o do erro *a priori* $e_k = y_k - \psi_k^T \hat{\theta}_{k-1}$, $\hat{\sigma}_{e,k}$, do ru do, $\hat{\sigma}_{v,k}$ e do produto $q_k = \psi_k^T P_k \psi_k$, $\hat{\sigma}_{q,k}$, e ϵ um valor positivo e pequeno, para que n o ocorra divis o por zero.

Esses desvios padr o s o obtidos a partir da estimativa de pot ncia, sendo essa definida para o erro *a priori* como, $\hat{\sigma}_{e,k}^2 = \alpha \hat{\sigma}_{e,k-1}^2 + (1-\alpha) e_k^2$ e para o ru do dada por, $\hat{\sigma}_{v,k}^2 = \beta \hat{\sigma}_{v,k-1}^2 + (1-\beta) e_k^2$, os par metros α e β correspondem ao fator de mem ria entre as estimativas no tempo. Em rela  o   vari vel q , tem-se que $\hat{\sigma}_{q,k}^2 = \alpha \hat{\sigma}_{q,k-1}^2 + (1-\alpha) q_k^2$.

Os principais par metros de configura  o, conforme notaa o do artigo original, s o escolhidos como, $\alpha=0,76$, $\beta=0,8$ e $\gamma=1,07$ e $\lambda_{\max}=0,99$.

3.2 Algoritmo RRPA-FE

Nesse algoritmo, (Beza e Bongiorno, 2014), 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 predi  o resultante $e_k = y_k - \psi_k^T \hat{\theta}_{k-1}$. 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.

A parametriza  o das vari veis de configura  o, conforme a notaa o do artigo original, s o dadas por, $\lambda_{ss}=0,99$, $\lambda_{tr}=0,95$, $d_{th}=0,41$ e $\tau_{hp}=0,4$.

3.3 Algoritmo CEPSR-FE

Para esse m todo de atualiza  o, (Bhotto e Antoniou, 2013), n o   necess rio pr -especificar um FE. A principal equa  o   dada por, $\hat{e}_{f,k} = \text{sign}(e_k) \max(|e_k| - t, 0)$, na qual $t = \sqrt{c_1 \sigma_v^2}$, sendo usada para calcular a estimativa do erro *a posteriori* sem ru do. Seu desvio padr o   estimado como, $\sigma_k = \beta \sigma_{k-1} + (1-\beta) \hat{e}_{f,k}^2$. Com isso, tem-se que o FE   dado por,

$$\lambda_k = 1 - \frac{2\sigma_k}{M(\sigma_k + c_1 \sigma_v^2)}, \quad (6)$$

em que determinou-se c_1 sendo um inteiro com valores na faixa entre 50 e 110 (para esse artigo), $M = n_\theta$, e σ_v^2   conhecida, e refere-se   vari ncia do ru do nos dados.

A configura  o desse algoritmo foi especificado como $M=3$, $c_1=110$, $\beta=0,9$, $\sigma_v^2=5,76 \times 10^{-4}$.

3.4 Algoritmo MC-FE

Esse m todo, (Vega et al., 2009), determina o tamanho do passo de corre  o por meio do chaveamento autom tico entre as pondera  es de atualiza  o impostas pelo MQR convencional, e fra  es

dessa. A atualização dos parâmetros é determinada como

$$\hat{\theta}_k = \hat{\theta}_{k-1} + \min \left(\sqrt{\delta_{k-1}}, \|\Delta \hat{\theta}_k^{RLS}\| \right) \frac{\Delta \hat{\theta}_k^{RLS}}{\|\Delta \hat{\theta}_k^{RLS}\|}, \quad (7)$$

em que $\Delta \hat{\theta}_k^{RLS} = K_k e_k$, sendo K_k o ganho de Kalman, e e_k o erro *a priori*. A sequência dos deltas é dada por $\delta_k = \alpha \delta_{k-1} + (1 - \alpha) \min(\delta_{k-1}, \|K_k\|^2 e_k^2)$, onde $0 < \alpha < 1$ é um fator de memória. Com o tempo, δ_k tende a um valor estacionário, diminuindo a capacidade de rastreamento, assim, tem-se a determinação de um método de controle para ambientes não estacionários, que determina quando δ_k será reinicializado.

Para as principais variáveis de configuração desse algoritmo, conforme notação do artigo original, têm-se, $\lambda=0,99$, $\alpha=0,65$, $M=3$, $V_T=1M$, $V_D=0,5V_T$ e $\zeta=40$.

4 Resultados Simulados

Nesta seção têm-se os resultados obtidos pelos métodos de estimação aplicados a um sistema massa mola amortecedor, em que se pretende estimar a constante elástica da mola κ que é variante. Sua representação discretizada em espaço de estados, com período de amostragem $T_s = 0,1$, é dada por:

$$\begin{bmatrix} x_{1,k} \\ x_{2,k} \end{bmatrix} = \begin{bmatrix} 1 & T_s \\ -\frac{\kappa T_s}{m} & 1 - \frac{c T_s}{m} \end{bmatrix} \begin{bmatrix} x_{1,k-1} \\ x_{2,k-1} \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{T_s}{m} \end{bmatrix} u_k, \quad (8)$$

sendo $x_{1,k}$ a posição, $x_{2,k}$ a velocidade, m refere-se à massa, c é o fator de amortecimento e κ corresponde à constante elástica da mola. A entrada u é a força externa aplicada ao sistema.

Considerando a equação (8), para estimação da constante elástica pode-se isolar a expressão de $x_{2,k}$, e reescrever no formato de regressão linear, no qual $y_k = x_{2,k}$, $\psi_k = [x_{1,k} \ x_{2,k} \ u_k]^T$ e $\hat{\theta} = [\hat{\theta}_1 \ \hat{\theta}_2 \ \hat{\theta}_3]^T$. Com isso, têm-se que, $\hat{\theta}_3 = \frac{T_s}{m}$, $\hat{\theta}_2 = \frac{1-cT_s}{m}$ e $\hat{\theta}_1 = -\frac{\kappa T_s}{m}$, de forma que a constante elástica pode ser estimada como $\hat{\kappa} = -\hat{\theta}_1 / \hat{\theta}_3$.

Para implementação, é adicionado um ruído branco gaussiano v na saída do modelo, ou seja, $y_k = x_{2,k} + v_k$, com variância σ_v^2 , que resulta numa relação sinal/ruído (SNR) de 20dB. Os valores usados para simulação são, $m=1$, $c=5$, $x_1(0)=0,1$, $x_2(0)=0,01$ e $\sigma_v^2=6 \times 10^{-4}$.

Para desenvolvimento de testes, são consideradas as situações em que o sinal de entrada possui ou não persistência de excitação e o parâmetro do sistema varia ou permanece constante. Na Figura 1, são ilustrados os cenários de interesse, para ambos o sinal de entrada transita entre o caso com e sem excitação. O cenário 1 corresponde ao caso que o parâmetro é variante, enquanto o mesmo é constante no cenário 2. Como sinal persistentemente excitante, optou-se pelo PRBS.

4.1 Estudo do Cenário 1

As estimativas resultantes para esse cenário são apresentadas na Figuras 2. Como pode ser no-




Figura 1: Comportamento dinâmico dos sinais para teste. (a) Sinal de entrada e (b) Variação da constante elástica. Ambos sinais foram divididos em dois cenários para teste, numerados como 1 e 2.

tado, os algoritmos produziram boas estimativas quando o sinal de entrada é persistentemente excitante. Para o intervalo em que essa excitação cessa (de 1000 a 2500), tais algoritmos tornaram-se menos eficientes, resultando em uma perda de precisão na estimação da constante elástica κ . O ideal nessa situação seria que cada algoritmo mantivesse o valor de FE máximo, com $\lambda=1$, ou TPC mínimo, com $g_k=0$, tal que os parâmetros não fossem atualizados. A principal diferença entre os algoritmos estudados, além do método usado para determinar o valor do fator de ponderação, seção 3, está na possibilidade do usuário pré-especificar ou não os limites de máximo e mínimo desse valor.




Figura 2: Estimativas da constante elástica para o cenário de teste 1. (a) algoritmos CRR-FE, C-MQR e RRPA-FE, e (b) algoritmos MC-FE e CEPSR-FE. As linhas verticais (--) indicam o instante em que ocorre a transição entre o sinal de entrada com e sem excitação.

No algoritmo CRR-FE não há a delimitação de menor valor do FE podendo esse atingir valores

pequenos, descartando assim, de modo significativo, o conhecimento dinâmico obtido dos dados anteriormente usados na estimação e atribuindo nesse momento maior peso aos dados recentes. Com isso, caso o algoritmo determine um FE pequeno para um intervalo que não se tenha excitação nos dados, uma pobre estimativa é obtida.

Para o algoritmo RRPA-FE os valores de mínimo e máximo do FE são especificados pelo usuário, assim como a delimitação do maior erro e tempo para transição entre os FE. A configuração desses é realizada a princípio de modo *offline* pela análise de dados dinâmicos do sistema, de modo que o algoritmo seja eficiente. Para o sistema massa mola estudado, isso foi averiguado no intervalo em que a entrada era constante e o algoritmo manteve o FE com valor máximo.

O algoritmo CEPSPR-FE faz o controle de atualização do FE sem a necessidade de especificar seus delimitantes. Porém, condições determinadas em (Bhotto e Antoniou, 2013) resultam em uma variação do FE em valores próximos do máximo. Para o cenário aqui estudado, durante o intervalo sem excitação, esse algoritmo manteve o FE máximo $\lambda = 1$, conforme desejado.

No algoritmo MC-FE tem-se que o FE é constante e que, para tratar a variação nos parâmetros, pondera-se o TPC. Pela configuração desse algoritmo, pretende-se inibir atualizações no modelo quando os dados não possuem relevância dinâmica. Porém, averiguou-se que em instantes que o sinal é excitante, também ocorre certa atenuação nas correções. Assim, pobres estimativas são obtidas quando não há excitação nos dados, devido ter-se abstraído pouca informação relevante durante os intervalos com excitação.

4.2 Estudo do Cenário 2

Neste cenário, o parâmetro do sistema é constante durante todo tempo de simulação. Escolheu-se $\kappa = 15$ e o sinal de entrada é o mesmo usado no cenário anterior. Na Figura 3, são mostradas as estimativas obtidas.

Ao contrário do que ocorreu no cenário 1, neste cenário os algoritmos não sofreram tanta degradação das estimativas no intervalo em que não há excitação. Entre as causas que explicam essa ocorrência, tem-se o fato de o parâmetro não variar no tempo, o que de certa forma produz menos atualizações do modelo por parte dos algoritmos durante esse intervalo. Com isso, tem-se para esse caso, uma baixa variância na estimativa do parâmetro, mantendo esse próximo ao verdadeiro.

4.3 Avaliação das Estimativas Resultantes

Como método de avaliação das estimativas obtidas por cada algoritmo, adotou-se o erro percentual




Figura 3: Estimativas da constante elástica para o cenário de teste 2. (a) algoritmos C-MQR, RRPA-FE e CRR-FE; (b) algoritmos CEPSPR-FE e MC-FE. As linhas verticais (--) indicam o instante em que ocorre a transição entre o sinal de entrada com e sem excitação.

Tabela 1: Avaliação das estimativas pelo método EPAM, para o sistema massa mola amortecedor.

Algoritmos	Índice EPAM	
	Cenário 1	Cenário 2
C-MQR	7,92	1,57
CRR-FE	4,88	1,61
RRPA-FE	3,31	1,59
CEPSR-FE	6,06	1,46
MC-FE	7,19	1,44

absoluto médio

$$EPAM = \frac{1}{N} \sum_{k=1}^N \frac{|y_k - \hat{y}_k|}{|y_k|}, \quad (9)$$

em que y_k é a saída medida, $\hat{y}_k = \psi_k^T \hat{\theta}_{k-1}$ é a saída estimada e N é a quantidade de amostras para análise. A Tabela 1 apresenta os valores quantitativos de desempenho.

Para o cenário 1, os algoritmos RRPA-FE e CRR-FE foram os que produziram estimativas mais acuradas, enquanto o algoritmo C-MQR produziu o pior índice EPMA. Isso pode ser explicado, pelo fato de os algoritmos com FE variante extraírem maior conhecimento do comportamento dinâmico do sistema, que varia no tempo, durante o intervalo em que a entrada era excitante. Dessa maneira, para o período em que a entrada é constante, esses algoritmos sofrem menor degradação.

No cenário 2, observou-se que os algoritmos menos conservadores (RRPA-FE e CRR-FE) absorveram de forma mais influente a contribuição vinda do ruído de medida. Com isso, houve um aumento da variância do parâmetro estimado, e consequentemente do índice EPAM.

5 Resultados Experimentais

Nesta seção, os métodos são aplicados para estimação de parâmetros de um modelo usado na

estimação da pressão de fundo para o processo de extração de petróleo. Um diagrama representativo desse processo é mostrado na Figura 4.




Figura 4: 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).

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), a qual é injetada na saída do reservatório. A densidade do fluido é então reduzida de modo 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).

Para os estudos aqui desenvolvidos é considerado o trabalho de (Proença, 2015), o qual identificou modelos para diferentes poços de produção da Petrobras. Dessa maneira, o modelo previamente especificado para o poço R, escolhido para estudos, é dado como,

$$y_k = 1,5634 y_{k-1} - 0,5715 y_{k-2} + 0,1174 u_{1,k-1} - 0,0696 u_{1,k-2} - 0,0176 u_{1,k-5} - 0,0502 u_{1,k-7} + 0,0158 u_{1,k-9} - 0,000038 u_{2,k-7} + 0,8482, \quad (10)$$

em que $u_{1,k}$ e $u_{2,k}$ são respectivamente a temperatura TT3 e vazão FT4, e y_k é a pressão PT1.

5.1 Estudo das estimativas

Na Figura 5, são apresentados os sinais de entrada e a saída medida, assim como as estimativas resultantes de acordo com os algoritmos de atualização estudados e para o caso da simulação livre (SL) do modelo (10) com parâmetros constantes.

O algoritmo MC-FE não é mostrado porque o mesmo diverge com o tempo. Para análise, escolheram-se 3 janelas de dados da massa de dados apresentada na Figura 5, que são delimitadas pelas linhas verticais mostradas na mesma. A primeira e terceira, referem-se a uma transição de patamar em que se percebe correlação dessa mudança devido às entradas. A segunda janela refere-se ao caso em que não se tem excitação persistente nas entradas.

5.2 Avaliação das Estimativas Resultantes

Na Tabela 2 são mostradas as avaliações encontradas para as estimativas resultantes. Para a estimação da PT1, os algoritmos CEPSSR-FE e RRPA-FE foram os que produziram melhores resultados quando comparados com os demais. O MC-FE não foi capaz de detectar a mudança de patamar em tempo hábil, deteriorando com isso sua estimativa, levando a divergência do algoritmo. Essa análise pode ser inferida devido os dados possuírem uma taxa de variância relevante, com informação dinâmica significativa para estimação. Por esse algoritmo atenuar o uso desses dados, o mesmo torna-se incapaz de acompanhar tais mudanças. Obviamente a SL do modelo com os parâmetros constantes produziu os piores resultados, sugerindo a vantagem de se usar métodos de atualização *online* de parâmetros.

Os algoritmos recursivos de atualização, alcançaram piores resultados para a estimação da janela 2, Figura 5(e). Isso pode ser explicado pela baixa persistência de excitação nessa janela.

Tabela 2: Avaliação das estimativas pelo método EPAM, considerando o Poço R estudado.

Algoritmos	Índice EPAM - Poço R		
	Janela 1	Janela 2	Janela 3
C-MQR	0,31	0,32	0,25
CRR-FE	0,31	0,32	0,24
RRPA-FE	0,23	0,24	0,20
CEPSSR-FE	0,20	0,21	0,20
SL	2,69	1,66	5,10

6 Conclusões

Neste trabalho são comparados métodos para a estimação de parâmetros variantes no tempo. Testes em um sistema simulado foram realizados para condições alternadas da persistência de excitação do sinal de entrada para sua identificação. Para finalizar foram aplicados os mesmos algoritmos de atualização dos parâmetros para o modelo de predição da pressão de fundo de poço de petróleo.

Pelas análises realizadas foi possível verificar que algumas características dos algoritmos recursivos para parâmetros variantes produzem melhorias significativas nos resultados, entre elas encontra-se a necessidade de se limitar os valores de ponderação.




Figura 5: Estimativas da pressão de fundo. (a) entrada TT3; (b) entrada FT4; (c) algoritmos CRR-FE, RRPA-FE, CEPSR-FE; (d) primeira e (e) segunda janela de dados estimados. As linhas verticais (--) especificam as 3 janelas de dados selecionadas, consideradas da esquerda para a direita, cada uma com 2000 amostras. O C-MQR está sobreposto com o CRR-FE. SL indica a simulação livre do modelo (10) com parâmetros constantes

Também foi averiguado por meio dos resultados alcançados, a vantagem ao se usar métodos *online* para estimação de parâmetros.

Dentre os algoritmos utilizados, o RRPA-FE produziu os melhores resultados na estimação de parâmetros variantes. Tal algoritmo também teve desempenho satisfatório para a atualização do modelo de predição da pressão de fundo de poço. Sua eficiência para estimação deve-se ao fato desse delimitar os valores de máximo e mínimo do FE.

Como proposta de trabalhos futuros, seria adequado o desenvolvimento de um método de ponderação que correlacionasse não apenas o erro de estimativa, mas também a persistência de excitação nos dados, gerando assim, uma correção mais adequada na ponderação dos dados.

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 fac-

tor for frequency component estimation in a generic input signal, *IEEE Transactions on Industry Applications* **50**(2): 1168–1176.

Bhotto, M. Z. A. e Antoniou, A. (2013). New improved recursive least-squares adaptive-filtering algorithms, *IEEE Transactions on Circuits and Systems I: Regular Papers* **60**(6): 1548–1558.

Ljung, L. (1998). *System identification: Theory for the User*, New Jersey: Prentice Hall.

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, Universidade Estadual Paulista (UNESP).

Paleologu, C., Benesty, J. e Ciochina, S. (2008). A robust variable forgetting factor recursive least-squares algorithm for system identification, *IEEE Signal Processing Letters* **15**: 597–600.

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.

Vega, L. R., Rey, H., Benesty, J. e Tressens, S. (2009). A fast robust recursive least-squares algorithm, *IEEE Transactions on Signal Processing* **57**(3): 1209–1216.

Teixeira, B. S. O., 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.