

COMPARAÇÃO ENTRE FILTROS DE KALMAN PARA ESTIMAÇÃO DA PRESSÃO DE FUNDO (PDG) NA PRODUÇÃO DE PETRÓLEO OFFSHORE

Abstract—The slugging is a characteristic effect of an offshore oil system, where there is intermittent flow of liquid and gaseous phase which are responsible for the system oscillations. Considering that these oscillations may damage the installation and they are related to decreases in oil production, it is essential to suppress this effect using pressure sensors in order to actuate in the process control valve. As the Pressure Downhole Gauge (PDG) does not always exist, or when it exists, it can often be unavailable, it is important to use some methodology to estimate this variable with other system measurements. In this work three techniques were applied and compared using Olga simulated data from a real oil well and the Diehl et al. (2017): discrete extended Kalman filter, constrained extended Kalman filter and unscented Kalman filter. The first filter was the most appropriated for this case, because it reproduced well the behavior of the process experimental data, also having less computational cost compared to the others. Furthermore, although the extended Kalman filter presents an offset in relation to the experimental data, this should not be a problem, once it is correct by the integral controller action.

Keywords—Offshore oil production, nonlinear systems, limit cycle, extended Kalman filter, constrained extended Kalman filter, unscented Kalman filter.

Resumo—A golfada é um efeito característico do sistema de petróleo *offshore*, onde há fluxo intermitente de fases líquida e gasosa, que é responsável pelas oscilações do sistema. Considerando que essas oscilações podem danificar a instalação e estão relacionadas a decréscimos na produção de petróleo, é essencial suprimir esse efeito utilizando sensores de pressão para atuar em válvulas de controle de processo. Como nem sempre existe sensor na PDG (Pressure Downhole Gauge), e quando existe esse pode estar frequentemente indisponível, é importante utilizar alguma metodologia para estimar essa variável com outras medições do sistema. Neste trabalho foram aplicadas e comparadas três técnicas utilizando dados simulados em Olga de um poço de petróleo real e o modelo de Diehl et al. (2017): filtro de Kalman estendido discreto, filtro de Kalman estendido com restrições e filtro de Kalman sem rastro. O primeiro filtro foi o que se mostrou mais adequado para o caso, pois conseguiu reproduzir bem o comportamento dos dados experimentais do processo, possuindo também menor custo computacional comparado com os demais. Além disso, apesar de o filtro de Kalman estendido apresentar um *offset* em relação aos dados experimentais, esse não deve ser um problema, uma vez que é corrigido pela ação integral do controlador.

Palavras-chave—Produção de petróleo *offshore*, sistemas não lineares, ciclo limite, filtro de Kalman estendido, filtro de Kalman estendido com restrições, filtro de Kalman sem rastro.

1 Introdução

Na produção de petróleo e gás por gás *lift*, a golfada é um efeito resultante da vazão multifásica em regime intermitente caracterizada por uma distribuição não homogênea de fases líquida e gasosa. Mais precisamente, vazões de gás com bolhas alongadas através do tubo, separadas por golfadas de líquido. Na saída isso se traduz em grandes períodos de produção muito baixa de líquido, periodicamente alternada com grandes picos de produção, os quais são problemáticos para o processo de separação. Além disso, a compressibilidade das bombas alongadas e a variação do peso da coluna de líquido causam oscilações periódicas na pressão em toda tubulação. Essas oscilações podem danificar a instalação e estão relacionadas a decréscimos na produção de petróleo (Falcimaigne and Decarre, 2008).

A PDG (*Permanent Downhole Gauge*) é considerada por alguns autores a variável mais importante para descrever a dinâmica de um poço de petróleo, e para monitorar a produção de óleo e gás. Essa pressão é considerada como uma das variáveis controladas mais importantes na produção de petróleo. Sabendo que a diminuição na produção desse produto resulta em perdas de lucro, é importante suprimir esse fenômeno das golfadas utilizando sensores de pressão em *loops* em *feedback* para atuar nas válvulas de controle (Campos et al., 2015). Di Meglio et al. (2012) utiliza apenas um controlador PI com um sensor da PDG, quando disponível. Godhavn et al. (2005) e Dalsmo et al. (2002) já reportaram implementações de tal método de controle que foram bem sucedidas.

É preciso considerar que nem sempre existe sensor na PDG, ou quando se tem, esses sensores localizados abaixo do mar ficam em ambiente hostil, que podem causar falha prematura e invalidar a manutenção dos mesmos devido aos altos custos envolvidos. Considerando a falta de medidas no sensor citado, diversos estudos propuseram a sua estimação com variáveis disponíveis no processo (Antonelo et al., 2017; Eikrem et al., 2008; Frooqnia et al., 2016; Grimstad and Foss, 2014; Pedersen et al., 2017; Riccio et al., 2015).

Neste trabalho serão testadas as utilizações dos filtro de Kalman estendido discreto (DEKF), filtro de Kalman estendido com restrições (CEKF) e filtro de Kalman sem rastro (UKF) para estimar a PDG utilizando dados simulados em Olga (simulador de vazão multifásico dinâmico - *OiL and GAs*) de um sistema de produção de petróleo *offshore* real utilizando o modelo de Diehl et al. (2017). Como essas metodologias são consideradas caixa cinza, então o modelo matemático e os dados históricos do processo são necessários para prever a variável desejada.

Além da introdução apresentada, o trabalho segue com a explicação das metodologias empregadas na Seção 2 e no modelo do estudo de caso na Seção 3. Os resultados e comparações para as metodologias são apresentados na Seção 4. O trabalho finaliza com as conclusões na Seção 5.

2 Metodologias aplicadas

Nessa seção são apresentadas as metodologias para a estimação da pressão da PDG. A seção é dividida em três partes, sendo que a primeira discute a técnica baseada em DEKF, a segunda na estrutura do CEKF e a terceira na teoria do UKF.

2.1 Filtro de Kalman Estendido Discreto

O filtro de Kalman usa medidas observadas ao longo do tempo (contendo ruído e outras discrepâncias) para produzir a estimação de variáveis desconhecidas. O filtro de Kalman estendido (EKF) foi desenvolvido pelo ramo de análise dinâmica da NASA para o sistema de navegação em tempo real das naves espaciais da missão Apollo, através do artigo publicado em 1960 por R. E. Kalman (Bogdanski and Best, 2017). Esse é um filtro aproximado para sistemas não lineares, baseados em linearização de primeira ordem das equações de estado em cada passo e no uso da teoria de estimação linear (Ljung, 1979).

Neste trabalho, o EKF em tempo discreto é utilizado (DEKF), o qual considera tempos discretos dinâmicos e medidas em tempos discretos. O sistema de equações não lineares é dado conforme segue (Simon, 2006):

$$\dot{x} = f(x, u, t) + \omega(t) \quad (1)$$

$$y_k = h_x(x_k, t_k) + v_k \quad (2)$$

Linearizando o sistema:

$$F(t) = \left(\frac{\partial f}{\partial x} \right)_{\hat{x}} \quad (3)$$

$$\varphi_{k-1} = e^{F(t_k - t_{k-1})} \quad (4)$$

$$H_k = \left(\frac{\partial h_k}{\partial x} \right)_{\hat{x}_{k|k-1}} \quad (5)$$

A covariância dos estados é:

$$P_{k|k-1} = \varphi_{k-1} P_{k-1|k-1} \varphi_{k-1}^T + Q_{k-1} \quad (6)$$

Dado o passo de correção

$$K_k = P_{k-1|k-1} H_k^T [H_k P_{k-1|k-1} H_k^T + R_k]^{-1} \quad (7)$$

os estados são atualizados como:

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k [y_k - h(\hat{x}_{k|k-1}, t_k)] \quad (8)$$

e a covariância dos novos estados é:

$$P_{k|k} = [I_n - K_k H_k] P_{k|k-1} \quad (9)$$

onde k representa o passo considerado no tempo discreto, x é o vetor de estados, f a função do modelo, ω o vetor dos ruídos de processo, y o vetor de saída, h a função que relaciona os estados com as saídas, v o vetor dos ruídos de medida, F a Jacobiana de f em relação aos estados, φ a matriz de transição de um estado para outro estado, H a Jacobiana de h em relação aos estados, P a matriz de covariância dos estados, Q a matriz de covariância do ruído de

processo, K o ganho de Kalman, R a matriz de covariância do ruído de medida e I a matriz identidade.

2.2 Filtro de Kalman Estendido com Restrições

O filtro de Kalman estendido com restrições (CEKF) advém da Estimativa de Horizonte Móvel (Moving Horizon Estimation) quando o comprimento do horizonte é igual a zero. Esse comprimento zero implica que as EDOs não são consideradas no problema de otimização, o qual simplifica a complexidade de resolução do problema de otimização dinâmico não linear (Franke et al., 2001).

Considerando ($N=0$) no problema de otimização da Estimativa de Horizonte Móvel, a formulação resultante é exatamente a formulação do filtro de Kalman estendido com restrições, conforme a seguir:

$$\min_{\omega_k, v_k} J = \omega_k^T P_k^{-1} \omega_k + v_k^T R^{-1} v_k \quad (10)$$

Com as seguintes restrições:

$$C \cdot \omega_k + v_k = y_k^{med} - h(x_k^{est}) \quad (11)$$

$$x_{min} - x_k^{est} \leq \omega_k \leq x_{max} - x_k^{est} \quad (12)$$

$$y_{min} - g(x_k^{est}) \leq C \cdot \omega_k + v_k \leq y_{max} - g(x_k^{est}) \quad (13)$$

A matriz de predição é dada via equação da matriz de Riccati em tempo discreto:

$$P_k = Q_k + \varphi_k P_{k-1} \varphi_k^T - (\varphi_k P_{k-1} \varphi_k^T) (C_k P_{k-1} C_k^T + R_k)^{-1} (\varphi_k P_{k-1} \varphi_k^T) \quad (14)$$

E a correção final por:

$$x_k^{cor} = x_k^{est} + \omega_k \quad (15)$$

$$y_k^{filt} = y_k^{med} - v_k \quad (16)$$

2.3 Filtro de Kalman sem rastro

Neste filtro, denominado *Unscented Kalman Filter* (UKF), a distribuição de estados é específica utilizando um mínimo conjunto de pontos amostrais cuidadosamente escolhidos. Esses pontos capturam completamente a média verdadeira e a covariância da variável gaussiana, e quando propagados através do verdadeiro sistema não linear, captura a média posterior e a covariância com precisão de segunda ordem (expansão da série de Taylor) para qualquer não linearidade (A. and Rudolph, 2002).

Primeiramente se tem o cálculo dos pontos sigma:

$$\chi_{k-1}^a = \begin{bmatrix} \hat{x}_{k-1}^a, & \hat{x}_{k-1}^a + \mu \sqrt{P_{k-1}^a}, \\ & \hat{x}_{k-1}^a - \mu \sqrt{P_{k-1}^a} \end{bmatrix} \quad (17)$$

$$\chi_{k|k-1}^x = f(\chi_{k-1}^x, u_{k-1}) \quad (18)$$

$$\hat{x}_k^- = \sum_{i=0}^{2ns} W_i^{(m)} \chi_{i,k|k-1}^x \quad (19)$$

$$P_k^- = \sum_{i=0}^{2ns} W_i^{(c)} (\chi_{i,k|k-1}^x - \hat{x}_k^-)(\chi_{i,k|k-1}^x - \hat{x}_k^-)^T \quad (20)$$

$$y_{k|k-1} = h(\chi_{k|k-1}^x) \quad (21)$$

$$P_{y_k y_k} = \sum_{i=0}^{2ns} W_i^{(c)} (y_{i,k|k-1} - y_k^-)(y_{i,k|k-1} - y_k^-)^T \quad (22)$$

$$P_{x_k y_k} = \sum_{i=0}^{2ns} W_i^{(c)} (\chi_{i,k|k-1}^x - \hat{x}_k^-)(y_{i,k|k-1} - y_k^-)^T \quad (23)$$

$$K_k = P_{x_k y_k} P_{y_k y_k}^{-1} \quad (24)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (y_k - \hat{y}_k^-) \quad (25)$$

$$P_k = P_k^- - K_k P_{y_k y_k} K_k^T \quad (26)$$

Onde

$$\mu = \sqrt{ns + \lambda} \quad (27)$$

$$\lambda = \alpha^2 (ns + \kappa) - ns \quad (28)$$

$$W_0^{(m)} = \frac{\lambda}{ns + \lambda} \quad (29)$$

$$W_0^{(c)} = \frac{\lambda}{ns + \lambda} + 1 - \alpha^2 + \beta \quad (30)$$

$$W_i^{(m)} = W_i^{(c)} = \frac{1}{2(ns + \lambda)}, \quad i = 1, \dots, 2ns \quad (31)$$

no qual ns é o número de estados, α é a distribuição de pontos ao redor da média ($1 \leq \alpha \leq 0$), β incorpora conhecimento à priori da distribuição da média (para variáveis gaussianas $\beta = 2$) e κ é um parâmetro de escalonamento secundário (geralmente ajustado como 0 ou $3 - ns$), χ e y são os pontos sigma dos estados e medidas, e $W_i^{(m)}$ e $W_i^{(c)}$ são os pesos das médias e covariâncias.

3 Estudo de caso

Neste trabalho o estudo de caso é o modelo de Diehl et al. (2017), o *Fast Offshore Well Model* (FOWM), que descreve o regime das golfadas em tubulações verticais dos processos de extração de petróleo, que é dividido em quatro subsistemas: *annular*, *tubing*, *flowline* e *riser*. Esse modelo pode ser aplicado a uma classe ampla de sistemas, indo de tubulações verticais a geometrias mais complexas como aquelas encontradas em instalações petrolíferas submarinas reais, as quais permitem a reprodução de regimes periódicos, trazendo uma visão da física do fenômeno das golfadas, conforme Figura 1.

Ao todo, o FOWM descreve o sistema de produção de petróleo com elevação tipo gás *lift* através de 6 EDOs e 25 EA. Neste trabalho, será apenas apresentado um resumo do equacionamento do modelo, o qual pode ser visualizado de forma completa no artigo de Diehl et al. (2017).




Figura 1. Visão esquemática da tubulação de transporte considerada. Retirado de: Diehl et al. (2017)

$$\frac{dm_{ga}}{dt} = w_{gc} - w_{iv} \quad (32)$$

$$\frac{dm_{gt}}{dt} = w_r \alpha_{gw} + w_{iv} - w_{whg} \quad (33)$$

$$\frac{dm_{lt}}{dt} = w_r (1 - \alpha_{gw}) - w_{whl} \quad (34)$$

$$\frac{dm_{gb}}{dt} = (1 - \epsilon) w_{whg} - w_g \quad (35)$$

$$\frac{dm_{gr}}{dt} = \epsilon w_{whg} + w_g - w_{gout} \quad (36)$$

$$\frac{dm_{lr}}{dt} = w_{whl} - w_{lout} \quad (37)$$

onde m_{gt} e m_{lt} são, respectivamente, a massa de gás e líquido no *tubing*, w_r é a vazão mássica total proveniente do reservatório, w_{whg} e w_{whl} são, respectivamente, as vazões mássicas de gás e líquido saindo do *tubing*, e α_{gw} é a fração mássica de gás presente no *tubing* dada por $m_{gt}/(m_{lt} + m_{gt})$, m_{gb} é a massa de gás acumulada na bolha à jusante da válvula virtual, m_{gr} e m_{lr} são, respectivamente, as massas de gás e líquido no *riser*, w_g é a vazão mássica de gás através da válvula virtual, w_{gout} e w_{lout} são as vazões mássicas de gás e líquido através da válvula de produção, respectivamente, e ϵ é a fração de gás que é desviada pela válvula virtual.

As vazões mássicas já suavizadas, em kg/s, são dadas por:

$$w_{iv} = K_a \sqrt{\rho_{ai} \frac{(p_{ai} - p_{tb}) + \sqrt{(p_{ai} - p_{tb})^2 + \epsilon}}{2}} \quad (38)$$

$$w_r = K_r \left(1 - 0.2 \left(\frac{p_{bh}}{p_r} \right) - 0.8 \left(\frac{p_{bh}}{p_r} \right)^2 \right) \quad (39)$$

$$= \alpha_{gt} K_w \sqrt{\rho_l \frac{w_{whg} (p_{tt} - p_{rb}) + \sqrt{(p_{tt} - p_{rb})^2 + \varepsilon}}{2}} \quad (40)$$

$$= (1 - \alpha_{gt}) K_w \sqrt{\rho_l \frac{w_{whl} (p_{tt} - p_{rb}) + \sqrt{(p_{tt} - p_{rb})^2 + \varepsilon}}{2}} \quad (41)$$

$$w_g = C_g \frac{(p_{eb} - p_{rb}) + \sqrt{(p_{eb} - p_{rb})^2 + \varepsilon}}{2} \quad (42)$$

$$w_{gout} = \alpha_g C_{out} u \sqrt{\rho_l \frac{(p_{rt} - p_s) + \sqrt{(p_{rt} - p_s)^2 + \varepsilon}}{2}} \quad (43)$$

$$w_{lout} = \alpha_l C_{out} u \sqrt{\rho_l \frac{(p_{rt} - p_s) + \sqrt{(p_{rt} - p_s)^2 + \varepsilon}}{2}} \quad (44)$$

onde p_{ai} é a pressão no ponto de injeção de gás de elevação no anular, p_{tb} é a pressão no ponto de injeção de gás de elevação no tubing, p_{tt} é a pressão no topo do tubing, p_{rb} é a pressão à montante da válvula virtual, p_{bh} é a pressão no ponto de injeção de gás de elevação no tubing, p_r é a pressão no reservatório, p_{rt} é a pressão no topo do riser, p_s é a pressão no separador e p_{eb} é a pressão na bolha acumulada; ρ_{ai} é a massa específica do gás no anular, ρ_l é a massa específica do óleo; α_{gt} é a fração mássica de gás no tubing, α_l é a fração mássica de líquido no flowline riser, α_g é a fração mássica de gás no pipeline riser; K_a é o coeficiente de fluxo da válvula de injeção, K_w é o coeficiente de fluxo da árvore de Natal, K_r é o coeficiente de fluxo do reservatório; C_{out} é o coeficiente da válvula de produção (choke) e u é a abertura da choke.

As pressões são dadas por:

$$\rho_{ai} = \frac{M p_{ai}}{RT} \quad (45)$$

$$\alpha_{gt} = \frac{m_{gt}}{m_{gt} + m_{lt}} \quad (46)$$

$$\alpha_{gr} = \frac{m_{gr}}{m_{gr} + m_{lr}} \quad (47)$$

$$\alpha_{lr} = 1 - \alpha_{gr} \quad (48)$$

$$p_{ai} = \left(\frac{RT}{V_a M} + g \frac{L_a}{V_a} \right) m_{ga} \quad (49)$$

$$p_{tb} = p_{tt} + \rho_{mt} g H_{vgl} \quad (50)$$

$$p_{bh} = p_{pdg} + \rho_{mres} g (H_t - H_{pdg}) \quad (51)$$

$$p_{pdg} = p_{tb} + \rho_{mres} g (H_{pdg} - H_{vgl}) \quad (52)$$

$$p_{tt} = \frac{\rho_{gt} RT}{M} \quad (53)$$

$$p_{rb} = p_{rt} + \frac{g \sin \theta}{A} (m_{lr} + m_{lstill}) \quad (54)$$

$$p_{eb} = \frac{RT}{M V_{eb}} m_{gb} \quad (55)$$

$$p_{rt} = \frac{RT}{M \left(V_r - \frac{m_{lr} + m_{lstill}}{\rho_l} \right)} m_{gr} \quad (56)$$

onde V_a é o volume do anular, V_{eb} é o volume da bolha acumulado à jusante da válvula virtual, V_r é o volume do riser, ρ_{mr} é a massa específica do líquido no riser, ρ_{mres} é a massa específica do líquido no reservatório, ρ_{mt} é a massa específica do líquido no tubing, ρ_{gt} é a massa específica do gás no tubing; m_{lstill} é a massa mínima de líquido no riser, M é a massa molar do gás de elevação; g é a constante gravitacional, T é a temperatura do sistema, R é a constante dos gases; H_a é o comprimento do anular, H_t é o comprimento do tubing, H_{pdg} é a distância até o medidor de pressão no tubing, H_{vgl} é a distância até o ponto de injeção de gás de elevação no tubing e θ é a inclinação do ponto de inflexão do riser.

Os parâmetros do modelo são dados na Tabela 1.

Tabela 1. Dados do sistema de produção simulados por Olga.

Parâmetro	Valor	Unidade
α_{gw}	0,026	-
D_a	0,1016	m
D	0,1739	m
D_t	0,1242	m
H_{pdg}	1392,2	m
H_t	1593,1	m
H_{vgl}	927,4	m
L	7894,4	m
L_a	937,4	m
L_t	1622	m
M	18	kg/kmol
p_r	3,52e7	Pa
p_s	1013250	Pa
ρ_l	965,5	kg/m ³
ρ_{mres}	902,5	kg/m ³
T	298	K
θ	$\pi/1,54$	rad
m_{lstill}	1,058e3	kg
C_g	3,39e-4	m ⁻¹
C_{out}	0,0031	m ⁻¹
V_{eb}	93,9382	m ³
ϵ	0,9183	-
K_w	0,0031	m ⁻¹
K_a	1,38e-4	m ⁻¹
V_r	118,87	m ³
K_r	96,291	m ⁻¹
W_{gc}	1,52	kg/s
u	0,5	-

As matrizes P_0 , R_0 e Q_0 foram determinadas utilizando a ordem de grandeza dos estados e medidas

dos dados experimentais, e são utilizadas para as três metodologias de filtro de Kalman apresentadas no trabalho:

$$P_0 = 1 \cdot 10^3 \cdot I_6 \quad (3)$$

$$R_0 = 1 \cdot 10^6 \cdot I_2 \quad (4)$$

$$Q_0 = 1 \cdot 10^3 \cdot I_6 \quad (5)$$

Para o UKF, os demais parâmetros de ajuste utilizados são: $\alpha = 1$, $\beta = 2$ e $\kappa = 0$.

4 Resultados

Os dados simulados advêm da simulação do modelo descrito no item anterior em Olga baseado em um poço de petróleo real. A Figura 2 apresenta a comparação da medição real da pressão da P_{pdg} estimada pela metodologia DEKF, onde apenas foi utilizada a pressão de topo do riser P_{rt} e pressão do topo do tubing P_{tt} como medidas experimentais.




Figura 2. Estimação da P_{pdg} com a metodologia DEKF, utilizando simulação em Olga em malha aberta.

Na figura mencionada, o resultado obtido pela metodologia DEKF possui comportamento oscilatório, apresentando apenas um *offset* em relação aos dados experimentais. A Figura 3 e 4 mostram, respectivamente, a estimação da pressão da P_{pdg} utilizando o CEKF e UKF.




Figura 3. Estimação da P_{pdg} com a metodologia CEKF, utilizando simulação em Olga em malha aberta.




Figura 4. Estimação da P_{pdg} com a metodologia UKF, utilizando simulação em Olga em malha aberta.

É possível observar que o comportamento dos dados experimentais e o estimado pelo DEKF, CEKF e UKF são bastante semelhantes. Considerando a aplicação para o controle de processos, o *bias* obtido por essas técnicas não deve ser um problema, uma vez que a ação integral do controlador é capaz de eliminá-lo. A Tabela 2 mostra mínimos quadrados entre os estimados pelas metodologias em relação aos dados simulados por Olga.

Tabela 2. Mínimos quadrados dos estimados pelas pressões da P_{pdg} estimadas pelos filtros em relação aos dados simulados pelo Olga.

Metodologia	DEKF	CEKF	UKF
Erro	1,21e-6	1,10e-6	5,84e-7
Tempo (s)	61,67	110,59	1905

Através da tabela se observa que o menor erro encontrado utilizando mínimos quadrados para os dados é para o UKF. No entanto, esse último filtro demora cerca de 31x mais para estimar do que o DEKF, enquanto o CEKF demora cerca de 2x mais tempo para estimar a P_{pdg} do que o DEKF. Através desse resultado é possível concluir que a utilização do DEKF é mais apropriada para este caso, uma vez que são erros relativamente pequenos em relação ao experimental e também necessita de menos esforço computacional devido a menor quantidade de simulações em comparação ao UKF.

A utilização do filtro de Kalman para a predição da pressão P_{pdg} utilizando medidas disponíveis experimentais, considerando fins de controle, foi bem sucedida. Além disso, essa metodologia possui a vantagem de utilizar o modelo fenomenológico do processo, onde há a incorporação da dinâmica das oscilações (ciclo limite) em suas equações.

5 Conclusão

O controle das oscilações das pressões é essencial em um sistema de petróleo *offshore*, uma vez que as

oscilações podem danificar a instalação e estão relacionadas a decréscimos na produção de petróleo. Como nem sempre existe sensor na pressão da PDG, é possível obter a estimativa dessas variáveis através de outras medidas do processo.

Neste trabalho foram comparados três filtros (DEKF, CEKF e UKF) para a estimação da P_{pdg} utilizando apenas a medida do topo do *tubing* (P_{it}) e do topo do *riser* (P_{rt}). O DEKF se mostrou o mais adequado para esse caso, pois conseguiu reproduzir bem o comportamento dos dados experimentais do processo possuindo, além disso, menor custo computacional do que os outros filtros.

A utilização do filtro de Kalman neste caso é mais apropriada, uma vez que esse possui um modelo fenomenológico, o qual é capaz de prever mudanças de dinâmica no sistema decorrentes do ciclo limite. Para propósitos de controle, mesmo que o resultado apresente um *offset* em relação aos dados experimentais, esse não é um problema, pois esse é corrigido pela ação integral do controlador.

Agradecimentos

Os autores agradecem a assistência da Universidade Federal do Rio Grande do Sul e o suporte financeiro da ANP e Petrobras.

Referências Bibliográficas

- A., W.E., Rudolph, van der M., 2002. The Unscented Kalman Filter. Kalman Filter. Neural Networks, Wiley Online Books.
- Antonelo, E.A., Camponogara, E., Foss, B., 2017. Echo State Networks for data-driven downhole pressure estimation in gas-lift oil wells. Neural Networks 85, 106–117.
- Bogdanski, K., Best, M.C., 2017. A new structure for non-linear black-box system identification using the extended Kalman filter. Proc. Inst. Mech. Eng. Part D J. Automob. Eng. 231, 2005–2015.
- Campos, M., Meien, O., Neto, S., Stender, A., Takahashi, T., Ashikawa, F., 2015. Anti-Slug Advanced Control for Offshore Production Platforms. OTC Bras.
- Dalsmo, M., Harvorsen, E., Slupphaug, O., 2002. Active feedback control of unstable wells at the brage field. In: SPE Annual Technical Conference.
- Di Meglio, F., Petit, N., Alstad, V., Kaasa, G.-O., 2012. Stabilization of slugging in oil production facilities with or without upstream pressure sensors. J. Process Control 22, 809–822.
- Diehl, F.C., Anzai, T.K., Almeida, C.S., Von Meien, O.F., Neto, S.S., Rosa, V.R., Campos, M.C.M.M., Reolon, F., Gerevini, G.G., Ranzan, C., Farenzena, M., Trierweiler, J.O., 2017. Fast Offshore Wells Model (FOWM): A practical dynamic model for multiphase oil production systems in deepwater and ultra-deepwater scenarios. Comput. Chem. Eng.
- Eikrem, G.O., Aamo, O.M., Foss, B.A., 2008. On Instability in Gas Lift Wells and Schemes for Stabilization by Automatic Control.
- Falcimaigne, J. (Jean), Decarre, S. (Sandrine), 2008. Multiphase Metering. In: Multiphase Production : Pipeline Transport, Pumping and Metering.
- Franke, M., Gesthuisen, R., Kraemer, S., Engell, S., 2001. Online monitoring of semi-continuous emulsion copolymerization: Comparing constrained extended Kalman filtering to feed-forward calorimetry. IFAC Proc. Vol. 34, 227–232.
- Frooqnia, A., Verdín, C.T., Sepehrnoori, K., 2016. Inference of rock pressure-production properties from gas-oil production logs. J. Nat. Gas Sci. Eng. 36, 124–143.
- Godhavn, J.M., Fard, M.P., Fuchs, P.H., 2005. New slug control strategies, tuning rules and experimental results. J. Process Control 15, 547–557.
- Grimstad, B., Foss, B., 2014. A nonlinear, adaptive observer for gas-lift wells operating under slowly varying reservoir pressure. IFAC Proc. Vol. 47, 2824–2829.
- Ljung, L., 1979. Asymptotic behavior of the extended Kalman filter as a parameter estimator for linear systems. IEEE Trans. Automat. Contr. 24, 36–50.
- Pedersen, S., Durdevic, P., Yang, Z., 2017. Challenges in slug modeling and control for offshore oil and gas productions: A review study. Int. J. Multiph. Flow 88, 270–284.
- Riccio, B.F., Teixeira, A.F., Teixeira, B.O.S., 2015. Downhole Pressure Soft-Sensing using Interacting Multiple Modeling* * This work was partially supported by Petrobras and CNPq. IFAC-PapersOnLine 48, 298–303.
- Simon, D., 2006. Optimal State Estimation: Kalman, H Infinity, and Nonlinear Approaches. Wiley-Interscience.