

Implementação em tempo real de um filtro de Kalman unscented para estimação de variáveis de difícil medição em um poço piloto operado por BCS

Odilon S. Luiz de Abreu* Erbet A. Costa* Tiago de O. Silva*
Marcos Pellegrini Ribeiro** Leizer Schnitman* Márcio A.F. Martins*

* Programa de Pós-Graduação em Mecatrônica, Universidade Federal da Bahia, Rua Aristides Novis, Federação, 40210-630, Salvador, BA, Brasil (e-mail: odilon.abreu@ufba.br) (e-mail: erbetcosta@ufba.br) (e-mail: silva.tiago@ufba.br) (e-mail: leizer@ufba.br) (e-mail: marciomartins@ufba.br).

** CENPES, Petrobras R&D Center, Av. Horácio Macedo 950, Cid. Universitária, Ilha do Fundão, Rio de Janeiro, RJ, Brasil (e-mail: mpellegrini@petrobras.com.br).

Abstract: This paper proposes the implementation of the soft sensor based on an unscented Kalman filter, aiming at experimental validation of variables of difficult measurements, such as fluid viscosity, productivity index, and production flow rate in a pilot plant operated by ESP (Electrical Submersible Pump), completely instrumented with supervision system, collect and data registration. ESP operates under severe conditions, and loss or failure of unknown variables is still a recurring problem in the oil fields onshore and offshore. The suitable tuning of the soft sensor in an experimental scenario, resulted an efficient solution of the variables within the 95% confidence interval in a continuous ESP operation within 26 hours of the experiment.

Resumo: Este trabalho propõe a implementação do sensor virtual baseado em filtro de Kalman unscented, visando a validação experimental de variáveis de difícil medição, tais quais, viscosidade do fluido, índice de produtividade e vazão de produção em uma planta piloto operado por BCS (Bombeio Centrífugo Submerso), completamente instrumentada com sistema de supervisão, coleta e registro de dados. O BCS opera em condições severas e a perda ou falha de medição e variáveis desconhecidas ainda é um problema recorrente nos campos de petróleo *onshore* e *offshore*. A sintonia adequada dos parâmetros do sensor virtual em cenário experimental, resultou uma solução eficiente na estimação das variáveis dentro do intervalo de confiança de 95% em uma operação contínua do BCS com 26 horas de experimento.

Keywords: Soft Sensor; Artificial Lift; ESP; Nonlinear Estimation

Palavras-chaves: Sensor virtual; Elevação Artificial; BCS; Estimação não linear.

1. INTRODUÇÃO

A instrumentação em um sistema de elevação artificial operado por BCS (Bombeio Centrífugo Submerso) é fundamental para previsibilidade da produção. Em verdade, os equipamentos industriais encontram-se sujeitos as altas pressões e temperaturas elevadas, isto torna o ambiente agressivo ao funcionamento e influência no tempo de vida útil de cada equipamento (Takacs, 2018).

O monitoramento contínuo das variáveis de processo no BCS é de interesse para o controle da produção. Todavia, quando ocorre perda ou falha de medição, o sistema de controle poderá ser desajustado, levando a uma redução parcial ou total na produção. Ademais, quando os instrumentos são danificados, a manutenção ou até mesmo a sua troca pode ser economicamente inviável.

De modo a contornar os problemas enfrentados no sensoriamento do BCS, a literatura sugere o uso de sensores virtuais (em inglês, *soft-sensors*) como alternativa para os sensores físicos, por onde têm ganhado espaço em aplicações industriais na área de petróleo e gás (Antonelo et al., 2017; Aguirre et al., 2017; Apio et al., 2019). No entanto, apesar de uma rica e extensa teoria existente, conforme Fortuna et al. (2007), poucos trabalhos foram encontrados em aplicações do BCS.

Em Binder et al. (2015), foi desenvolvido um *soft-sensor* de horizonte móvel, isto é, o MHE (*Moving Horizon Estimation*) para estimar as variáveis do processo (vazão, viscosidade e índice de produtividade) em uma planta BCS. O algoritmo foi testado em simulação e os resultados garantiram estimativas satisfatórias quando a planta está sujeita a mudança operacional e concluíram que o algoritmo pode ser implementado no caso prático. No trabalho de Ganat et al. (2015), os autores projetaram um sensor virtual

baseado em modelo contendo equações físicas e correlações empíricas para estimar a vazão de produção. O método foi confrontado em ambiente de simulação no OLGA (*Dynamic Multiphase Flow Simulator*) em poços equipado por BCS e os resultados indicaram estimativas aceitáveis nos cenários apresentados. Outrossim, Delou (2019) propõe um MSKF (*Model Scheduling Kalman Filter*) como *soft-sensor* para estimar a viscosidade do fluido. Os resultados em simulação apontaram estimativas assertivas no BCS, porém, quando as incertezas associadas ao modelo eram altas, os valores estimados não correspondiam.

Enquanto os trabalhos citados abordam a validação dos algoritmos em ambiente computacional, uma lacuna pouco explorada na literatura é a validação experimental dos sensores virtuais em BCS. Neste sentido, é proposto neste trabalho um sensor virtual baseado no filtro de Kalman unscented, visando a validação experimental das variáveis tipicamente de difícil medição em uma planta piloto BCS. Especificamente, as variáveis estimadas são: viscosidade do fluido; índice de produtividade e vazão na coluna de produção.

Este é o primeiro estudo que investiga com dados reais a estimação destas variáveis em um poço equipado com BCS, completamente instrumentado, com sistema de supervisão, coleta e registro de dados.

O restante do texto está organizado da seguinte forma. Na Seção 2 detalha-se a planta piloto BCS e as variáveis que serão estimadas. Na Seção 3 são enunciados os fundamentos teóricos referente ao sensor virtual para o tratamento do problema. Finalmente, na Seção 4 discute-se os resultados experimentais obtidos, seguida pela Seção 5, que encerra o texto com as considerações finais.

2. DESCRIÇÃO E MODELAGEM DO BOMBEIO CENTRÍFUGO SUBMERSO

2.1 Planta BCS-LEA

O sistema BCS usado neste artigo é um protótipo instalado no LEA (Laboratório de Elevação Artificial) da UFBA (Universidade Federal da Bahia) e é composto por um sensor de fundo (Centinel 3), motor série 450 (FMHX) de 18 HP e uma bomba P4 PMXSSD de série 400 de 15 estágios. O processo é monitorado pelos instrumentos de superfície (PT-103; FCV-101; PIT-104; TIT-100; FT-101) e subsuperfície (PT-101; FT-102; PT-102). Um tanque de armazenamento com capacidade de 1500L de óleo mineral, Lubrax Hydra XP 10, este possui uma viscosidade maior que a água, 10,53 cSt @40°C, na qual é utilizado para simular o escoamento do petróleo durante a produção.

Tal ambiente representa as dinâmicas próximas de uma realidade de um poço de petróleo equipado por BCS e permite extrair e manipular os dados em tempo real onde possibilita aplicações e análises dos sensores virtuais. Uma representação em diagrama de blocos do sistema em estudo pode ser vista na Fig. (1).

2.2 Modelagem BCS-LEA

O modelo matemático que representa o comportamento dinâmico de um poço equipado por BCS é encontrado em

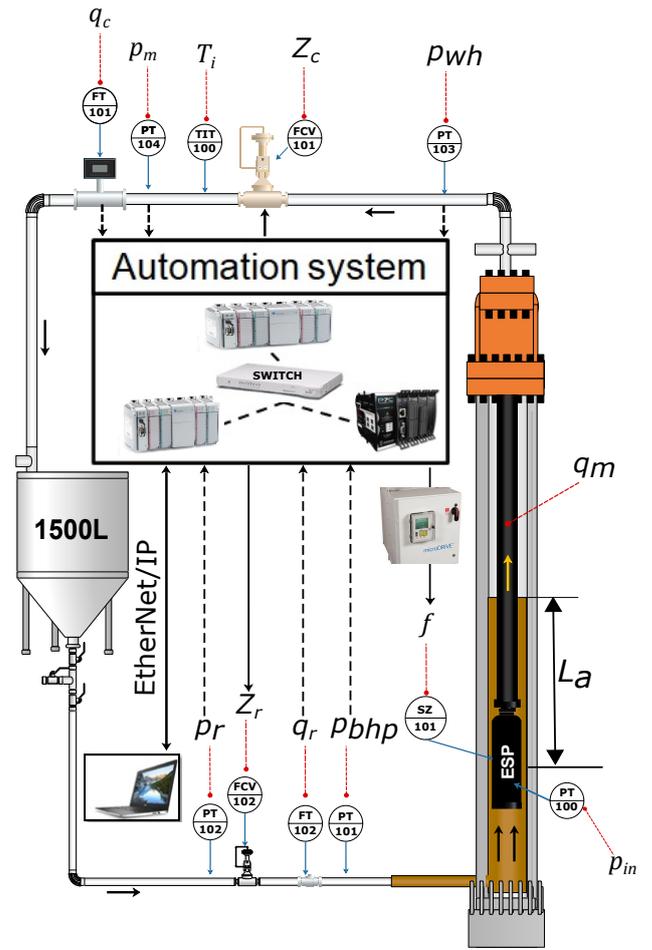


Figura 1. Diagrama de automação do BCS-LEA

Pavlov et al. (2014); Binder et al. (2015); Krishnamoorthy et al. (2016). Dentre tais trabalhos, os autores não tratam o acúmulo de massa na região do anular, característica tal de um BCS *onshore*. Sob esse viés, Costa et al. (2021) modificou o modelo utilizado na literatura para adequar a dinâmica do anular e a nova composição do sistema de equações diferenciais que descreve o comportamento do BCS-LEA é descrita a seguir:

$$\frac{dL_a}{dt} = \frac{1}{A_{ann}}(q_r - q_m), \quad (1)$$

$$\frac{dp_{wh}}{dt} = \frac{\beta_2}{V_2}(q_m - q_c), \quad (2)$$

$$\frac{dq_m}{dt} = \frac{\bar{A}}{\bar{\rho}l}(p_{bh} - p_{wh} + \Delta p_p - \Delta p_h - \Delta p_f), \quad (3)$$

e as seguintes equações algébricas:

$$q_r = IP(p_r - p_{bh}), \quad (4)$$

$$q_c = K_c \sqrt{(p_{wh} - p_m)}, \quad (5)$$

$$\Delta p_p = \rho g H,$$

$$H = C_H(\mu) H_0(q_0) \left(\frac{f}{f_0} \right)^2, \quad (6)$$

$$q_0 = \frac{q_m}{C_q(\mu)} \left(\frac{f_0}{f} \right),$$

em que L_a é a variação do nível na região do anular; A_{ann} é a área do tubo de produção no anular; q_r , vazão

de reservatório definida na Eq. (4); e q_m , vazão média na coluna de produção. p_{wh} é a variação da pressão na choke; β_2 o módulo de compressibilidade; V_2 define o volume de controle e q_c vazão na choke obtida na Eq. (5). p_{bh} é a pressão fundo; Δp_p é o incremento de pressão inserido pela bomba que é definido por H (*Head*) e corrigido pela viscosidade do fluido (μ); vazão (q_0); e a lei de afinidade ($\frac{f}{f_0}$), conforme Eq. (6). Por fim, o Δp_h é a variação da pressão hidrostática e Δp_f a perda de carga por fricção. Para mais detalhes das equações e parâmetros não mencionados do sistema, consultar o Costa et al. (2021).

2.3 Parâmetros desconhecidos

O modelo dinâmico (Eq. (1) - (6)) descreve o comportamento real do sistema BCS e neste caso algumas variáveis e/ou parâmetros desconhecidos podem diminuir o MTBF (*Mean-Time between failures*) dos equipamentos, tais como:

- Viscosidade do fluido (μ): Dependendo das propriedades do fluido e das condições operacionais envolvendo pressão e temperatura, a viscosidade pode mudar com o passar do tempo e as mudanças podem interferir na produção e comprometer os componentes da bomba (impelidor/difusor), na qual está sujeito à degradação.
- Índice de produtividade (*IP*): Tem impacto direto na malha de controle para manter o BCS operando dentro dos limites de segurança e está relacionado com outras fontes incertas, ou seja, vazão de reservatório, pressão de fundo do poço, dentre outros.
- Vazão da bomba (q_m): É de suma importância na construção da curva de desempenho, monitoramento do processo e controle e previsibilidade da produção. No entanto, esta variável é de difícil monitoramento.

Como o BCS opera diariamente e as variações de temperatura em um poço afetam as propriedades da viscosidade, optou-se μ como o parâmetro desconhecido a ser estimado. Por conseguinte, o *IP* corresponde na diminuição energia do reservatório e precisa ser monitorado (explorado) e por fim, q_m , afere a produtividade da bomba. Tais variáveis, serão estimadas pelo sensor virtual na Seção 3.

3. SENSOR VIRTUAL

3.1 Definição do problema

Um projeto do sensor virtual baseado em modelo para estimação de variáveis tipicamente de difícil medição é abordado nesta seção. De modo que o modelo BCS (Eq. (1) - (6)) é não linear, um sistema equações em estados discretos pode ser escrita da seguinte forma:

$$\begin{aligned} \mathbf{x}_k &= f_{k-1}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{p}_{k-1}) + \mathbf{w}_{k-1}, \\ \mathbf{y}_k &= h_k(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k, \end{aligned} \quad (7)$$

em que $f_k(\cdot)$ é uma função não linear que descreve o comportamento dinâmico da planta e $h_k(\cdot)$ é uma função não linear da medição. $\mathbf{x}_k = [L_a ; p_{wh} ; q_m ; p]^\top$, em que $\mathbf{p}_k = [\mu ; IP]^\top$ é o vetor de estados e os parâmetros desconhecidos; $\mathbf{u}_k = [f ; Z_c]^\top$ é vetor das manipuladas do

BCS-LEA, e $\mathbf{y}_k = [L_a ; p_{wh}]^\top$ são as medições do modelo. $\mathbf{w}_k \sim N(0, \mathbf{Q}_k)$ e $\mathbf{v}_k \sim N(0, \mathbf{R}_k)$ são ruídos do processo e de medição nas quais são vetores aleatórios, gaussianos, de média zero e mutuamente independentes. O objetivo é obter uma estimativa de estados aumentados $\hat{\mathbf{x}}_k$ e a matriz de covariância \mathbf{P}_k tal que minimize o erro de estimação. Para isso, o método proposto será apresentado a seguir.

3.2 Filtro de Kalman unscented

A técnica de estimação de estados tal qual o UKF (*unscented Kalman filter*) vem se destacando na literatura, devido à sua utilização em sistemas não lineares, uma vez que a planta BCS-LEA estudada neste artigo, é um poço de petróleo *onshore* que tem características altamente não lineares. Segundo Julier and Uhlmann (2004), o sucesso do UKF está em utilizar a UT (*Unscented Transform*), o que difere significativamente da estratégia de linearização, como faz o EKF (*Extended Kalman Filter*). A UT define pontos determinísticos, conhecido como pontos sigma, que são propagados na função não linear (Eq. (7)), em que a média e a covariância sejam calculados a partir desses pontos. A formulação da UT é consolidado nas seguintes expressões:

$$\begin{aligned} \mathbf{x}_0 &= \bar{\mathbf{x}}, \\ \mathbf{x}_i &= \bar{\mathbf{x}} + \theta \cdot (\sqrt{\mathbf{P}_x})_i, \quad i = 1, \dots, L \\ \mathbf{x}_i &= \bar{\mathbf{x}} - \theta \cdot (\sqrt{\mathbf{P}_x})_{i-L}, \quad i = L + 1, \dots, 2L \end{aligned} \quad (8)$$

onde \mathbf{x} é um vetor de variáveis aleatórias com dimensão L ; $\bar{\mathbf{x}}$ a média de \mathbf{x} ; \mathbf{P}_x matriz de covariância e θ determina quão espalhados os pontos sigma estão de $\bar{\mathbf{x}}$. O cálculo de θ é apresentado em Dan Simon (2006). Já o termo $(\sqrt{\mathbf{P}_x})_i$ é a i -ésima coluna da matriz $\sqrt{\mathbf{P}_x}$. Em seguida, os pontos sigma (\mathbf{x}_i) são propagados através da função não linear f , tal que:

$$\mathbf{y}_i = f(\mathbf{x}_i) \quad i = 1, \dots, 2L \quad (9)$$

Para aproximar a média e a matriz de covariância do modelo do processo \mathbf{y}_k , utiliza-se uma média ponderada dos vetores \mathbf{y}_i , de acordo com as Eqs. (10) e (11). Note-se que estas estatísticas são definidas a partir dos pontos sigma a *posteriori* com pesos definidos, \mathbf{w}_i , em (12) a saber:

$$\bar{\mathbf{y}}_k \approx \sum_{i=1}^{2L} \mathbf{w}_i^m \mathbf{y}_i, \quad (10)$$

$$\mathbf{P}_y \approx \sum_{i=1}^{2L} \mathbf{w}_i^c \{ \mathbf{y}_i - \bar{\mathbf{y}}_k \} \{ \mathbf{y}_i - \bar{\mathbf{y}}_k \}^T, \quad (11)$$

$$\begin{aligned} \mathbf{w}_0^m &= \lambda / (L + \lambda), \\ \mathbf{w}_0^c &= \lambda / (L + \lambda) + [1 - \alpha^2 + \beta], \\ \mathbf{w}_i^m &= \mathbf{w}_i^c = 1 / \{2(L + \lambda)\}, \quad i = 1, 2, \dots, 2L \end{aligned} \quad (12)$$

em que λ e α são parâmetros de sintonia e a variável β é usada para inserir conhecimento a *priori* da distribuição de \mathbf{x} (por exemplo, $\beta = 2$ é uma distribuição gaussiana). Dessa maneira, ao utilizarmos um UKF em um sistema não linear, a transformada provê as informações necessárias para o cálculo das estimativas do filtro. O algoritmo recursivo do UKF nas etapas de predição e correção é demonstrado no diagrama de bloco da Fig. (2).

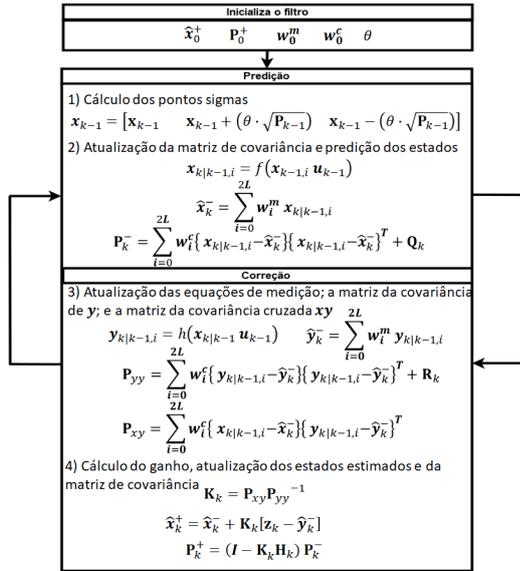


Figura 2. Diagrama recursivo do UKF

4. IMPLEMENTAÇÃO DO UKF NA PLANTA PILOTO BCS

Nesta seção, avalia-se o desempenho do UKF na planta piloto BCS-LEA para monitoramento das variáveis de processo e estimação de variáveis de difícil medição. Na Fig. (1), observa-se as variáveis de entrada, ou seja, $\mathbf{u}_k = [f; Z_c]^T$ que serão utilizadas no modelo do sensor virtual em (7). Por conseguinte, as variáveis medidas em $\mathbf{z}_k = [L_a; p_{wh}]^T$. A escolha dessas variáveis levou em consideração a pouca instrumentação que geralmente é encontrada em qualquer campo produtor operado por BCS. Uma vez que a planta dispõe dessas medições, o papel do UKF é monitorar e estimar o estado aumentado $\hat{\mathbf{x}}_k = [L_a; p_{wh}; q_m; \mu; IP]^T$. A Tab. (1) descreve as variáveis utilizadas no BCS-LEA para estudo de caso.

Tabela 1. Variáveis do BCS-LEA

Variáveis		Status
p_{wh}	Pressão choke (bar)	on
L_a	Nível do anular (m)	on
p_m	Pressão Manifold (bar)	on
p_{in}	Pressão Intake (bar)	off
p_r	Pressão reserv. (bar)	off
p_{bh}	Pressão fundo (bar)	off
q_r	Vazão de reserv. (m ³ /h)	off
q_c	Vazão na choke (m ³ /h)	off
T_i	Temp. do fluido (°C)	off
f	Frequência (Hz)	on
Z_c	Válvula choke (%)	on
q_m	Vazão da bomba (m ³ /h)	estimada
μ	Viscosidade do fluido (cP)	estimada
IP	Índice de produtividade (m ³ /h/bar)	estimada

Do ponto de vista de sintonia, os parâmetros foram obtidos em ambiente computacional, de modo a serem os menores valores possíveis capazes de manter a resposta do filtro dentro de um intervalo de confiança de $\pm 2\sigma$ (95%), tais como: $\mathbf{R}_k = [0.0019; 0.0016] \mathbf{I}_{2 \times 2}$, definida pela variância das medições no estado estacionário; $\mathbf{Q}_k = [0.0064; 0.0031; 0.002; 1.32e-05; 2.78e-11] \mathbf{I}_{5 \times 5}$, pre-

enchida com os valores iniciais dos estados no estado estacionário; $\mathbf{P}_0 = \mathbf{Q}_k$ compõe a estimativa inicial da matriz de covariância; $\beta=2$ define a distribuição gaussiana e $\alpha = 0.05$ corresponde a distribuição dos pontos sigma na estimativa.

No início do experimento, o BCS-LEA estava em operação (estado estacionário) por volta das 10:00 horas do dia 18 set. 2021. Em seguida, novos pontos operacionais foram atingidos durante as mudanças das variáveis manipuladas (f e Z_c) de forma simultânea, conforme a Fig. (3). Vale ressaltar que os atuadores têm um tempo de resposta. Nesse sentido, foi considerado um sinal de rampa para capturar a dinâmica da planta no transiente, na qual pode ser observada na imagem ampliada. O experimento termina no dia 19 set. 2021, aproximadamente às 13:00 horas, com um tempo total de 26 horas em operação.

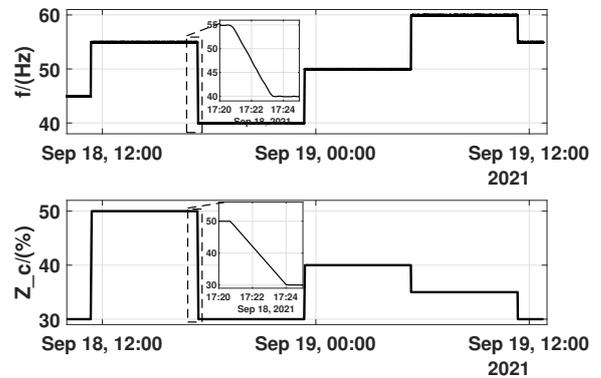


Figura 3. Variáveis manipuladas

As Figs. (4) e (5) apresentam o monitoramento do UKF durante a filtragem das variáveis medidas. Na Fig. (4), observa-se inicialmente que sensor virtual parte na mesma condição inicial da planta e encontra-se dentro da região de convergência ($\pm 2\sigma$). No instante 23:22 horas, o BCS-LEA tem uma nova mudança operacional, conforme a imagem ampliada, e o algoritmo conseguiu rastrear a variável medida durante o transiente, melhorando a cada minuto a sua estimativa dentro das incertezas. Posteriormente, o sistema estabiliza e uma nova condição e o regime permanente é alcançado.

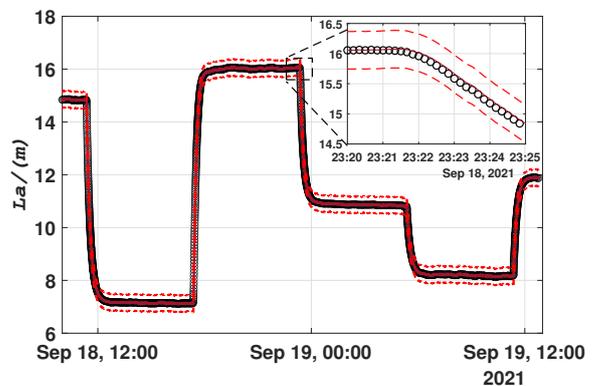


Figura 4. Monitoramento (fundo): Medição (o); UKF (-); $\pm 2\sigma$ (--)

Na Fig. (5), percebe-se que durante a mudança operacional (f e Z_c), o UKF conseguiu capturar a dinâmica da pressão na choke (18-set. 11:20 até 11:25 horas) e atendeu o monitoramento da variável dentro do intervalo de confiança em outros pontos operacionais.

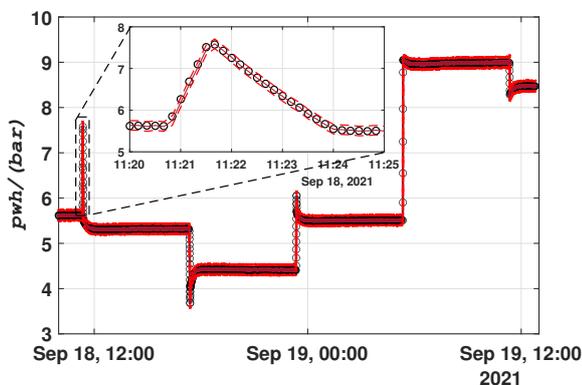


Figura 5. Monitoramento (superfície): Medição (o); UKF (-); $\pm 2\sigma$ (--)

A Fig. (6) ilustra o desempenho do sensor virtual na estimação da viscosidade, aonde tem impacto direto nos equipamentos da bomba e precisa ser monitorada. Como referência na validação, utilizou-se uma equação da viscosidade em função da temperatura (T_i) obtida em laboratório por um viscosímetro, conforme a Fig. (9) no apêndice. O resultado confirma o desempenho satisfatório do estimador durante o experimento, dentro do intervalo de confiança do processo com valores coerentes das características do fluido de modo que MSE (erro médio quadrático) foi de aproximadamente 0,4188. Além disso, é comprovada a eficácia da estimativa na região de mínima e máxima temperatura do fluido por serem inversamente proporcionais, ou seja, $\uparrow \mu \cdot T_i \cdot \downarrow$.

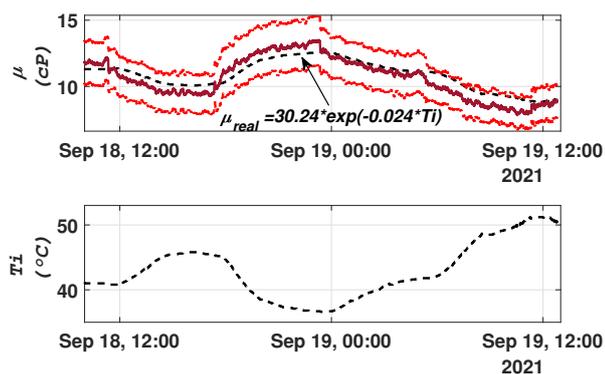


Figura 6. Variável estimada: Validação (---); UKF (-); $\pm 2\sigma$ (--)

Outra variável de difícil medição que tem impacto direto na malha de controle e precisa ser monitorada de forma contínua é o índice de produtividade (IP) do poço onde está relacionado com o fator de recuperação do reservatório de petróleo. Na Fig. (7), ilustra o comportamento estimado do IP e percebe-se que o UKF conseguiu descrever as variações dinâmicas no fundo do poço (ver em Fig. (4))

após as mudanças operacionais de f e Z_c . Ademais, à diminuição do IP em torno de 12:10 até 17:00 horas é um reflexo da atenuação do reservatório quando o BCS-LEA opera no ponto de maior vazão em regime permanente. Para fins de validação, substituiu o IP na Eq. (4) e utilizou-se como referência a vazão real do reservatório medido por um coriolis (ver, apêndice Fig. (10b)), tal qual confirma que o valor estimado foi adequado com MSE de aproximadamente 0,0101.

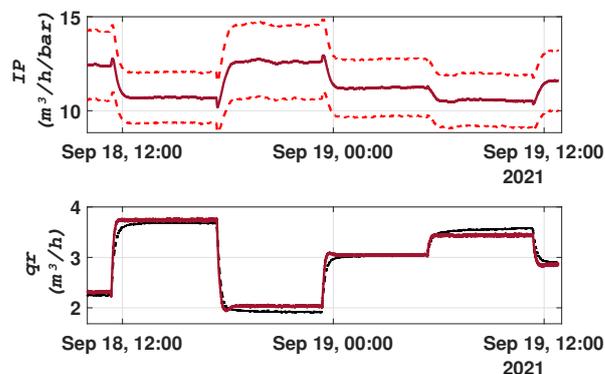


Figura 7. Variável estimada: Validação (---); UKF (-); $\pm 2\sigma$ (--)

Finalmente, é apresentado a estimação da variável de processo que está diretamente relacionada com a eficiência produtiva da extração de petróleo, ou seja, vazão de óleo produzida. De forma similar ao IP , o valor real do processo (ver, apêndice Fig. (10a)) é apresentado, respectivamente. É observado na Fig. (8) que o sensor virtual conseguiu seguir a trajetória análoga da vazão quando a planta está sujeita a pequenas ou grandes variações operacionais, dentro das incertezas associadas e sem nenhum conhecimento prévio do sensor físico em todo o experimento. O erro médio quadrático foi de 0,07 durante o regime permanente e/ou transitório e confirma que os parâmetros de sintonia do estimador foram adequados.

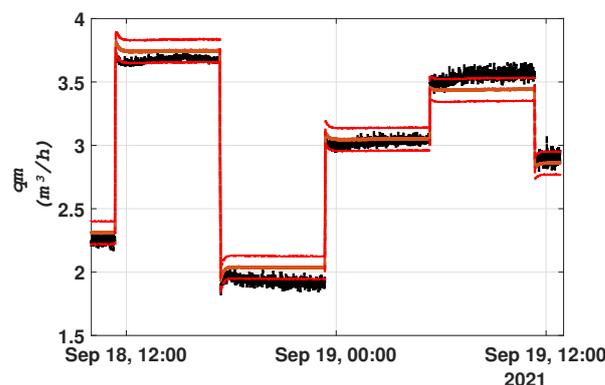


Figura 8. Variável estimada: Validação (---); UKF (-); $\pm 2\sigma$ (--)

5. CONCLUSÃO

Neste trabalho a implementação do sensor virtual baseado em modelo foi utilizado para monitoramento contínuo das

variáveis de processo e estimação de variáveis não medidas em uma planta experimental BCS-LEA. Diante dos resultados experimentais, o UKF demonstrou estimativas aceitáveis dentro do intervalo de confiança de 95% e mostrou-se uma alternativa satisfatória no monitoramento dos sensores físicos e na estimação de variáveis de difícil medição no caso prático, como foi demonstrado para viscosidade, índice de produtividade e vazão de produção que até o presente trabalho preenche uma importante lacuna na literatura de petróleo e gás. Portanto, o método proposto pode futuramente contribuir para o aumento da produção e para o aprimoramento dos sistemas de controle automático em plantas BCS com instrumentação local limitada.

AGRADECIMENTOS

Os autores agradecem ao CNPq, CAPES, FAPESB, LEA e Petrobras pelo apoio financeiro para a realização do experimento.

REFERÊNCIAS

- Aguirre, L.A., Teixeira, B.O., Barbosa, B.H., Teixeira, A.F., Campos, M.C., and Mendes, E.M. (2017). Development of soft sensors for permanent downhole Gauges in deepwater oil wells. *Control Engineering Practice*, 65(August), 83–99. doi:10.1016/j.conengprac.2017.06.002.
- Antonelo, E.A., Camponogara, E., and Foss, B. (2017). Echo State Networks for data-driven downhole pressure estimation in gas-lift oil wells. *Neural Networks*, 106–117. doi:10.1016/j.neunet.2016.09.009.
- Apio, A., Dambros, J.W., Farenzena, M., and Trierweiler, J.O. (2019). Comparison of Kalman filter-based approaches for permanent downhole gauge pressure estimation in offshore oil production. *Journal of Petroleum Science and Engineering*, 182(March), 106254. doi:10.1016/j.petrol.2019.106254.
- Binder, B.J.T., Pavlov, A., and Johansen, T.A. (2015). Estimation of flow rate and viscosity in a well with an electric submersible pump using moving horizon estimation. *IFAC-PapersOnLine*, 28(6), 140–146.
- Costa, E.A., Abreu, O.S.L.D., Silva, T.D.O., Ribeiro, M.P., and Schnitman, L. (2021). A Bayesian approach to the dynamic modeling of ESP-lifted oil well systems: An experimental validation on an ESP prototype. *Journal of Petroleum Science and Engineering*. doi:10.1016/j.petrol.2021.108880.
- Dan Simon (2006). *Optimal State Estimation Kalman, Hinf, and Nonlinear Approaches*.
- Delou, P.A. (2019). Adaptive Model Predictive Control Applied to Submersible Pump Lifted Wells. *Dissertação de mestrado, Universidade Federal do Rio de Janeiro*.
- Fortuna, L., Graziani, S., Rizzo, A., and Xibilia, M.G. (2007). *Soft Sensors for Monitoring and Control of Industrial Processes*. 9.
- Ganat, T.A., Hrairi, M., Hawlader, M.N., and Farj, O. (2015). Development of a novel method to estimate fluid flow rate in oil wells using electrical submersible pump. *Journal of Petroleum Science and Engineering*, 135, 466–475. doi:10.1016/j.petrol.2015.09.029.
- Julier, S.J. and Uhlmann, J.K. (2004). Unscented filtering and nonlinear estimation. In *Proceedings of the IEEE*. doi:10.1109/JPROC.2003.823141.
- Krishnamoorthy, D., Bergheim, E.M., Pavlov, A., Fredriksen, M., and Fjalestad, K. (2016). Modelling and Robustness Analysis of Model Predictive Control for Electrical Submersible Pump Lifted Heavy Oil Wells. *IFAC-PapersOnLine*, 49(7), 544–549.
- Pavlov, A., Krishnamoorthy, D., Fjalestad, K., Aske, E., and Fredriksen, M. (2014). Modelling and model predictive control of oil wells with Electric Submersible Pumps. In *2014 IEEE Conference on Control Applications (CCA)*, 3905, 586–592. IEEE.
- Takacs, G. (2018). *Electrical Submersible Pumps Manual*. Elsevier. doi:10.1016/C2017-0-01308-3.

6. APÊNDICE - APARATO EXPERIMENTAL



Figura 9. Teste em bancada para determinar a equação de viscosidade do óleo mineral, Lubrax Hydra XP 10, coletadas no BCS-LEA.

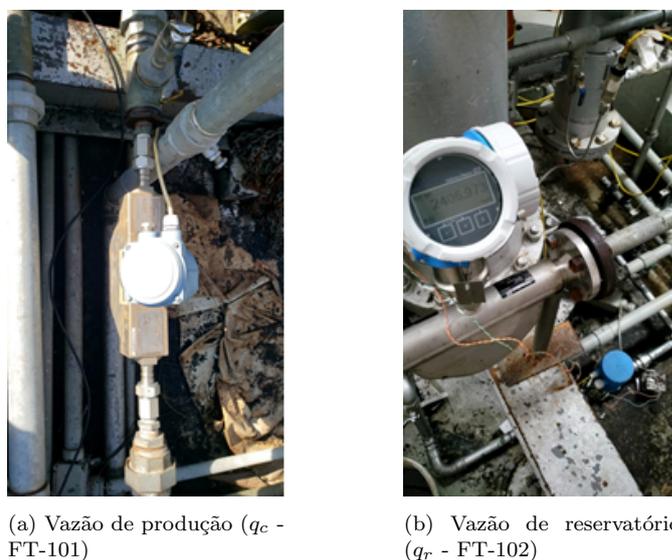


Figura 10. Medidores de vazão do tipo coriolis para validação do estimador.