

MODELAGEM MATEMÁTICA PARA PROJETO DE SENSORES VIRTUAIS DE PRESSÃO DE FUNDO DE POÇOS DE PETRÓLEO

BRUNO O. S. TEIXEIRA*, LUCAS B. PROENÇA*, MÁRIO C. M. M. CAMPOS†

**Dep. de Eng. Eletrônica, Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, Brasil*

†*Centro de Pesquisas e Desenvolvimento (CENPES), Petróleo Brasileiro S.A., Rio de Janeiro, Brasil*

Emails: brunoot@ufmg.br, lucasbpro@gmail.com, mariocampos@petrobras.com.br

Abstract— This paper employs soft sensing techniques based on system identification and hybrid stochastic filtering to determine the downhole pressure of gas-lift oil wells. Linear mathematical models are obtained for five oil wells. Next, such models are used in Kalman filters, which are combined in a bank of interacting multiple models, covering different operating scenarios for each oil well. Also, we investigate and implement strategies for dual state and parameter estimation, allowing the soft sensor to be more robust to time-varying dynamics.

Keywords— Soft sensor, system identification, stochastic filtering, downhole pressure.

Resumo— Este trabalho aplica técnicas de instrumentação virtual baseadas em identificação de sistemas e filtragem estocástica híbrida para a determinação da pressão de fundo de poço em poços de extração de petróleo. Modelos matemáticos lineares são obtidos para cinco poços. Em seguida, tais modelos são usados em filtros de Kalman, os quais são utilizados para compor um banco de múltiplos modelos interativos, tratando assim diferentes cenários de operação dos poços. Também são investigadas e implementadas estratégias de estimação dual de estados e parâmetros do sistema, tornando o sensor virtual mais robusto a variações temporais dos poços.

Palavras-chave— Sensor virtual, identificação de sistemas, filtragem estocástica, pressão de fundo de poço.

1 Introdução

Sensores virtuais são modelos matemáticos preditivos que inferem os valores de uma dada variável de processo a partir de medições de outras variáveis (Kadlec et al., 2009; Khatibisepehr et al., 2013). Eles vêm sendo aplicados na indústria petroquímica como alternativa a sensores físicos (Domlan et al., 2011; Fujiwara et al., 2012). Há duas categorias de sensores virtuais: orientados a modelos e orientados a dados (Kadlec et al., 2009). Os primeiros empregam modelos fenomenológicos, ao passo que os últimos fazem uso de modelos caixa preta. Considerando que os processos industriais são descritos por fenômenos não-lineares, modelos não-lineares (Pagano et al., 2006; Riccio et al., 2015) ou lineares por partes (Domlan et al., 2011) são geralmente obtidos para produzir sensores virtuais.

A pressão de fundo de poço é uma grandeza extremamente importante para engenheiros de petróleo porque é usada no monitoramento, controle e otimização dos poços perfurados. Todavia, dar manutenção ou substituir sensores de fundo de poço (PDG, do inglês, *permanent downhole pressure*) é uma tarefa desafiadora em poços *offshore* (Eck et al., 1999). Nesse contexto, técnicas de sensoreamento virtual são uma opção promissora.

Este trabalho dá continuidade aos estudos de (Teixeira et al., 2014; Riccio et al., 2015). Utiliza-se uma metodologia de duas etapas para estimar de forma *online* a pressão de fundo de poço de cinco diferentes poços. Primeiramente, modelos lineares polinomiais são obtidos a partir de dados históricos, para diferentes configurações de sinais

de entrada e saída. Em seguida, bancos de filtros de Kalman são implementados com esses modelos. Ou seja, modelos lineares locais são combinados em “malha fechada” a fim de produzir estimativas da pressão de fundo de poço que sejam mais acuradas e precisas que aquelas produzidas pela simulação livre de modelos (em “malha aberta”).

Em (Riccio et al., 2015), verificou-se que o emprego de modelos não-lineares não causou melhoria significativa na acurácia das estimativas quando comparado ao caso em que somente modelos lineares eram testados. Assim, como é mais fácil estender uma mesma estrutura de modelos lineares para diferentes poços, garantindo estabilidade global de tais modelos, este trabalho opta por obter apenas modelos lineares para os cinco poços investigados. Aqui, uma mesma estrutura de modelos é proposta para todos os poços, a fim de tornar mais facilmente replicável a metodologia usada para outros poços. Além disso, investiga-se a possibilidade de atualizar recursivamente tais modelos a fim de tratar o envelhecimento do poço, bem como outros fenômenos dinâmicos não previstos nos dados de identificação. Este artigo reporta os principais resultados obtidos por (Proença, 2015).

2 Descrição do Processo

Gas lift é um processo de elevação artificial usado em poços de petróleo de águas profundas. Um diagrama simplificado de um poço deste tipo é mostrado na Figura 1. A Tabela 1 lista algumas das variáveis de processo frequentemente medidas.

O processo é resumido como a seguir. Gás




Figura 1: Diagrama P&ID de um poço de petróleo com *gas-lift*, em que TT e PT são os transmissores de temperatura e pressão. Uma visão geral é mostrada em (a), ao passo que a plataforma é detalhada em (b). 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.

Tabela 1: Variáveis de processo.

Tag	Descrição	Unidade
PT1	Pressão de fundo de poço (PDG)	kgf/s ²
TT1	Temp. de fundo de poço (PDG)	°C
PT2	Pressão da árvore de natal molhada	kgf/s ²
TT2	Temp. da árvore de natal molhada	°C
PT3a	Pressão mont. da válv. SDV	kgf/cm ²
PT3	Pressão mont. da válv. <i>choke</i> prod.	kgf/cm ²
PT3b	Pressão jus. da válv. <i>choke</i> prod.	kgf/cm ²
TT3	Temp. mont. da válv. <i>choke</i> prod.	°C
FV3	Abertura da válv. <i>choke</i> prod.	%
PT4b	Pressão jus. da válv. SDV <i>gas lift</i>	kgf/cm ²
PT4a	Pressão mont. da válv. SDV <i>gas lift</i>	kgf/cm ²
TT4	Temp. mont. da válv. SDV <i>gas lift</i>	°C
FT4	Vazão instantânea de <i>gas lift</i>	m ³ /h
FV4	Abertura da válv. de <i>gas lift</i>	%
PT4	Pressão jus. da válv. <i>choke gas lift</i>	kgf/cm ²

pressurizado flui através da tubulação de gas lift na direção da plataforma (tag 4) rumo à árvore de natal no leito marinho, 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).

3 Metodologia

Considere o sistema dinâmico linear discreto

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

$$y_k = C_kx_k + D_ku_k^h + v_k, \quad (2)$$

em que $x_{k-1} \in \mathbb{R}^n$ é o vetor de estados; $y_k \in \mathbb{R}^m$ é a variável de observação; A_{k-1} , B_{k-1} são matrizes associadas a um modelo de processo f ; C_k e D_k são matrizes que representam um modelo de observação h ; $u_k \triangleq \begin{bmatrix} u_{k-1}^f \\ u_k^h \end{bmatrix} \in \mathbb{R}^p$ é o vetor das entradas dos modelos de processo e observação; $w_{k-1} \in \mathbb{R}^n$ e $v_k \in \mathbb{R}^m$ são os ruídos de processo e medição com média nula e covariância Q e R , respectivamente. Neste trabalho, x_k é definido como a sequência dos n últimos valores da pressão de fundo de poço. O projeto de sensores virtuais de pressão de fundo de poços de petróleo é aqui dividido em duas etapas; conforme Figura 2. Utiliza-se a mesma metodologia usada em (Teixeira et al., 2014). Cinco poços são considerados: E, M, N, P, e R.

Na etapa de *identificação de sistemas*, são estimados três pares modelos de processo e observação, $\{\hat{f}^s, \hat{h}^s\}$, $s = 1, 2, 3$, de forma *offline* para cada poço. Cada par de modelos utiliza diferentes configurações de sinais de entrada u_k^s e saída y_k^s de acordo com a Tabela 2. Tais modelos são identificados na representação ARX polinomial (do inglês, *AutoRegressive with eXogenous inputs*) como $z(k) = \psi^T(k-1)\theta$, em que $z(k)$ é a saída, $\psi(k-1)$ é o vetor de regressores dado por valores passados da saída com atraso máximo n_z e das entradas com atraso máximo n_u e θ é o vetor de parâmetros, conforme (Aguirre, 2005) e reescritos em espaço de estados como (1)-(2). Os modelos de cada par são obtidos a partir de um conjunto de dados dinâmicos $\{u_k, x_k, y_k\}$, $k = 1, \dots, N$, recuperados de um sistema histórico PIMS a um período de amostragem de 1min. Janelas de dados com transientes em diferentes pontos de operação são detectadas usando o algoritmo proposto em (Ribeiro e Aguirre, 2015) e usadas para identificação ou validação dos modelos. Para cada par de modelos, as matrizes Q e R são obtidas a partir do cálculo das variâncias σ_w^2 e σ_v^2 dos erros de simulação livre dos respectivos modelos.

Na etapa de *banco de filtros*, os pares de modelos $\{\hat{f}^s, \hat{h}^s\}$ são combinados conforme Tabela 2




Figura 2: Metodologia de desenvolvimento de sensor virtual de pressão de fundo de poço em poços de petróleo.

Tabela 2: Diferentes estruturas utilizadas para composição dos pares de modelos $\{\hat{f}^s, \hat{h}^s\}$. A pressão de fundo de poço (PT1) é utilizada sempre como saída x_k nos modelos de processo $\hat{f}^s$ e como entrada u_k^h nos modelos de observação $\hat{h}^s$.

Par s	Tipos de variáveis utilizadas	u_k^f de f^s	x_k de f^s	u_k^h de h^s	y_k^h de h^s
1	Variáveis da árvore de natal molhada	PT2, TT2	PT1	PT1, TT2	PT2
2	Variáveis da linha de produção	PT3, TT3	PT1	PT1, PT3a	PT3
3	Variáveis da linha de produção e <i>gas lift</i>	PT4, TT3	PT1	PT1, PT3a	PT3

para implementar três filtros de Kalman paralelos (aqui designados por KFs, $s = 1, 2, 3$), cada um gerando recursivamente estimativas $\hat{x}_{k|k}^s$ com covariância $P_{k|k}^{x,x,s}$ a partir de medições $\{u_k^s, y_k^s\}$, $k > 0$. Esses filtros têm suas estimativas combinadas por meio de um banco de filtros IMM (do inglês, *Interacting Multiple Models*) para cada poço, gerando uma estimativa *online* $\hat{x}_{k|k}$ mais precisa para a pressão de fundo de poço. Também se investiga a possibilidade de estimar um ou todos os parâmetros dos modelos de cada filtro por meio de uma abordagem dual, na qual um estimador recursivo de mínimos quadrados com fator de esquecimento é usado para estimar o(s) parâmetro(s) paralelamente a cada filtro.

É importante destacar que x é assumidamente conhecido durante intervalo N apenas na etapa de identificação de sistemas. Observe que, por meio da abordagem de banco de filtros, a variável x é estimada por meio de um esquema em “malha fechada”, no qual a correção é feita por meio do modelo de observação. Maiores detalhes da metodologia são apresentados em (Teixeira et al., 2014).

4 Resultados Experimentais

4.1 Modelagem

Neste trabalho, a fim de definir uma metodologia mais facilmente reproduzível em vários poços, buscou-se definir uma estrutura comum aos modelos de todos os cinco poços. Assim, inicialmente, desenvolveu-se uma criteriosa análise de (i) quais variáveis entre aquelas listadas na Tabela 1 deve-




Figura 3: Relevância das variáveis candidatas para a explicação de PT1 a partir de testes de correlação.

riam compor cada modelo $\hat{f}^s$ ou $\hat{h}^s$ por meio de testes de correlação conforme (Aguirre, 2005; Khatibisepehr et al., 2013) e (ii) qual o máximo atraso na saída n_z e na entrada n_u de cada modelo (ordem) usando o critério de informação de Akaike.

A Figura 3 sugere que existem características em comum entre os poços. A fatia de correlação ocupada pelo conjunto das variáveis medidas na árvore de natal, PT2 e TT2, é sempre considerável. Quanto às variáveis de produção, as entradas PT3 e TT3 parecem ser uma escolha interessante para compor entradas de modelos. Fi-

nalmente, analisando-se as variáveis medidas na linha de injeção de *gas lift*, percebe-se que os dados de pressão são mais relevantes para composição de modelos do que aqueles relacionados à vazão ou à abertura de válvulas de *gas lift*. Assim, foram testadas diversas combinações de entradas para modelos, tentando-se padronizar ao máximo a estrutura dos mesmos para os cinco poços de interesse. Ao final desses testes, conseguiu-se generalizar a estrutura dos modelos diferenciando-os nos três tipos descritos na Tabela 2. Observe que os tipos 2 e 3 só utilizam variáveis da plataforma. Em alguns poços, não há medições de variáveis na árvore de natal, cujos instrumentos estão localizados no leito marinho (tipo 1). Em (Teixeira et al., 2014; Riccio et al., 2015), observou-se que as variáveis do leito marinho não são indispensáveis para estimação na pressão de fundo de poço.

A partir de conhecimento prévio do processo, vale destacar que não é interessante a utilização de variáveis de *gas lift* como únicas entradas de modelos. Isso porque as mesmas não conseguem explicar as flutuações das variáveis da produção, embora sejam importantes na explicação das variações no ponto de operação em estado estacionário. Isso justifica o tipo 3 de modelos. O chamado regime de golfadas severas, por exemplo, provoca oscilações de pressão e temperatura nas variáveis de produção (tipos 2 e 3), mas não nas variáveis de *gas lift*.

A partir do critério de Akaike, verificou-se que, de uma forma geral, 9 termos mostraram-se suficientes para composição dos vários tipos de modelos com $n_z = 2$ e $n_u = 9$.

Para ilustrar, são apresentados dois modelos ARX polinomiais obtidos. Para o poço M, tem-se o modelo $\hat{f}^2$:

$$\begin{aligned} z(k) = & 1,629 z(k-1) - 0,826 z(k-2) \\ & - 0,07676 u_2(k-1) + 0,02513 u_2(k-3) \\ & - 0,02802 u_2(k-7) - 0,01276 u_1(k-2) \\ & + 0,716 \times 10^{-2} u_1(k-4) + 0,04621 u_2(k-9) \\ & - 0,05507 u_2(k-8), \end{aligned} \quad (3)$$

em que $u_1(k)$ é dado por PT3, $u_2(k)$ por TT3 e $z(k)$ por PT1. Para o poço P, tem-se $\hat{h}^2$:

$$\begin{aligned} z(k) = & 0,5191 u_2(k-5) + 2,795 u_1(k-2) \\ & - 4,392 u_1(k-3) + 0,07645 u_2(k-8) \\ & + 0,3517 z(k-2) - 0,1518 u_2(k-9) \\ & + 0,1637 z(k-1) - 0,04635 u_2(k-7) \\ & + 1,606 u_1(k-4). \end{aligned} \quad (4)$$

em que $u_1(k)$ é dado por PT1, $u_2(k)$ por PT3a e $z(k)$ por PT3. A Figura 4 mostra a validação de alguns modelos, incluindo-se os supracitados.

4.2 Estimação de estados

Os filtros implementados são divididos em três tipos, KF1, KF2 e KF3, conforme Tabela 2. As





Figura 4: Validação de modelos de processo e observação por simulação livre. Modelos de (a) processo $\hat{f}^1$, $\hat{f}^2$ e $\hat{f}^3$ do poço M e de (b) observação $\hat{h}^2$ do poço P.

estimativas dos KFs implementados para os poços E, R e P estão representadas na Figura 5. Percebe-se, primeiramente, grande diferença no comportamento da pressão de fundo nos três poços. Por exemplo, enquanto no poço E ela varia muito pouco (variância de $20 \text{ kgf}^2/\text{cm}^4$), no poço R são observados diversos transientes e mudanças de patamar (variância de $334 \text{ kgf}^2/\text{cm}^4$).


A presença de poucos transientes na pressão de fundo é a principal dificuldade para a obtenção de modelos. Nota-se que, para o poço R, os três filtros de Kalman se ajustam bem aos dados históricos, ao passo que, para o poço E, o erro de estimação dos filtros obtidos é maior.

Na Figura 5a percebe-se a ocorrência dos eventos de fechamento de poço. Tal fenômeno produz uma elevação repentina no valor de PT1, representando uma dinâmica que os modelos obtidos não conseguem explicar. Claramente, as estimativas dos filtros KF1 e KF2 divergem bastante do valor real da pressão de fundo durante o fechamento, porém, a partir da reabertura, os filtros convergem para valores próximos das medidas.


Para o poço P foi observada uma divergência entre as estimativas dos filtros a partir da segunda metade do gráfico (vide Figura 5). A pressão de fundo apresenta uma leve tendência de diminuição, a qual também é observada com maior ou menor intensidade em outras variáveis do processo. Daí a diferença entre as estimativas dos filtros e a justificativa de se utilizar um banco de filtros



(a) Poço E



(b) Poço R



(c) Poço P

Figura 5: Estimativa da PT1 para os poços E, R e P. Comparam-se as estimativas dos filtros KFs, $s = 1, 2, 3$, e do banco de filtros IMM. As linhas horizontais representam os limites das janelas consideradas no cálculo dos índices RMSE (vide Figura 6).

IMM para a estimação da pressão de fundo.

Os índices RMSE do erro de estimação dos filtros e bancos de filtros, para cada poço analisado nesse trabalho, estão representados na Figura 6. Tais índices são calculados para diferentes janelas de dados, numeradas de 1 a 6 no topo dos gráficos. Observa-se que o índice RMSE torna-se mais elevado em janelas onde ocorre fechamento de poço, como é o caso dos poços E e P. Faz-se, portanto, necessário o tratamento desses eventos.

4.3 Estimação dual de estados e parâmetros

A fim de tornar a metodologia mais robusta às variações temporais da dinâmica e ao tratamento de pontos de operação não visitados pelos dados

Tabela 3: Diferentes estratégias de estimação dual de estados e parâmetros utilizadas. Comparam-se os índices RMSE globais verificados para cada poço.

Poço	Bancos de filtros IMM		
	sem est. de parâm.	com estim. de um parâm.	com estim. de todos os parâm.
E	8,1	8,2	não convergiu
M	8,5	9,5	5,5
N	2,9	3,1	não convergiu
R	4,3	4,2	20,5
P	10,4	13,3	16,7

de identificação usados para construir os modelos, investiga-se a possibilidade de estimar parâmetros dos modelos de processo junto com o vetor de estados por meio de uma abordagem dual. Para tal, o fator de esquecimento de $\lambda = 0,9999$ é sintonizado para o algoritmo de mínimos quadrados recursivo, de forma que apenas mudanças de longo prazo e persistentes na dinâmica da pressão de fundo tenham alguma influência na estimação dos parâmetros.

Primeiramente, é testado o caso em que somente um parâmetro de cada modelo é estimado recursivamente. Nesse caso, escolhe-se o parâmetro associado ao regressor $z(k-1)$ de cada modelo ARX, pois o mesmo tem grande importância na explicação de $z(k)$. Em geral, como sugere a Tabela 3, a ressonância de um parâmetro dos modelos piorou levemente as estimativas de PT1.

Em seguida, investigou-se a estratégia de estimação de todos os parâmetros dos modelos de processo. Foi verificado que, assim como na estimação de apenas um parâmetro, a pouca persistência de excitação dos dados pode levar a estimativas piores do que aquelas verificadas sem a atualização de parâmetros do sistema. Em alguns casos (vide Tabela 3), as estimativas chegaram a divergir.

5 Conclusões

Este trabalho desenvolveu sensores virtuais para estimação de pressão de fundo de poços de petróleo. A partir de dados históricos, foram identificados modelos ARX para cinco poços. Tais modelos foram utilizados na composição de filtros de Kalman e bancos de filtros IMM.

Com o objetivo de padronizar a estrutura dos modelos para os diferentes poços, foram testadas várias combinações de variáveis para obtenção de modelos, priorizando-se aquelas mais correlacionadas com a pressão de fundo. Definiu-se, ao final desse procedimento, três tipos diferentes de filtros: os que utilizam variáveis do leito submarino; os que utilizam variáveis da linha de produção; os que utilizam variáveis da linha de produção e injeção de *gas lift*. As estruturas definidas e os modelos lineares obtidos se mostraram adequados para o sistema. As estimativas obtidas por meio dos bancos de filtros lineares produziram re-




Figura 6: Estimação de estados para os cinco poços. Comparação entre os índices RMSE dos filtros KFs, $s = 1, 2, 3$, e bancos de filtros IMM. Os índices são calculados para diferentes janelas de dados, destacadas pelas linhas verticais da Figura 5. As linhas horizontais representam a média global do índice RMSE para os respectivos filtros ou banco de filtros.

sultados competitivos a aqueles apresentados em (Riccio et al., 2015). No entanto, quando pontos de operação não presentes nos dados de identificação eram testados, o desempenho da estimação do banco de filtros foi prejudicado.

Foram investigadas técnicas de estimação dual de estados e parâmetros. Tal proposta permite a ressintonia dos modelos obtidos *offline*, tornando o sensor virtual mais robusto a variações temporais na dinâmica do poço. Foi implementado, então, o algoritmo de mínimos quadrados recursivo com fator de esquecimento, buscando fazer as amostras mais recentes de medições do processo terem mais influência sobre a sintonia de parâmetros. Percebeu-se, contudo, que para dados com pouca persistência de excitação o desempenho do algoritmo diminui consideravelmente.

Agradecimentos

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

Referências

- L.A. Aguirre (1995). A nonlinear correlation function for selecting the delay time in dynamical reconstructions. *Physics Letters A*, 203(2-3): 88-94.
- E. Domlan, B. Huang, F. Xu, and A. Espejo (2011). A decoupled multiple model approach for soft sensors design. *Control Engineering Practice*, 19: 126-134.
- J. Eck, U. Ewherido, et al. (1999). Downhole Monitoring: The Story So Far. *Oilfield Review*, 11(4): 20-33.

- K. Fujiwara, M. Kano, and S. Hasebe (2012). Development of correlation-based pattern recognition algorithm and adaptive soft-sensor design. *Control Engineering Practice*, 20: 371-378.
- P. Kadlec, B. Gabrys, and S. Strandt (2009). Data-driven soft sensors in the process industry. *Computers and Chemical Engineering*, 33(4): 795-814, 2009.
- S. Khatibisepehr, B. Huang and S. Khare (2013). Design of inferential sensors in the process industry: A review of Bayesian methods. *Journal of Process Control*, 23(10): 1575-1596.
- D.J. Pagano, V. Dallagnol Filho and A. Plucênio (2006). Identification of Polynomial NARMAX Models for an Oil Well Operating by Continuous Gas-Lift. *IFAC Intern. Symp. on Advanced Control of Chemical Processes*, Gramado, Brazil, 1113-1118.
- L.B. Proença (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.
- A.H. Ribeiro and L.A. Aguirre (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.
- B.F. Riccio, A. F. Teixeira, and B. O. S. Teixeira (2015). Downhole Pressure Soft-Sensing using Interacting Multiple Modeling. *2nd IFAC Workshop on Automatic Control in Offshore Oil and Gas Production*, Florianópolis, Brasil, 298-303.
- B.O.S. Teixeira, W.S. Castro, A.F. Teixeira and L.A. Aguirre (2014). Data-driven soft sensor of downhole pressure for a gas-lift oil well. *Control Engineering Practice*, 22(1): 34-43.