

DETECÇÃO DE FALHAS EM TANQUES INTERATIVOS UTILIZANDO UMA ABORDAGEM NEURAL/FUZZY/BAYESIANA PARA DETECÇÃO DE PONTO DE MUDANÇA

Marcos Flávio S. V. D'Angelo, Douglas H. Fonseca Silva

Departamento de Ciência da Computação, UNIMONTES

marcos.dangelo@unimontes.br, dougashfsilva@gmail.com

Walmir M. Caminhas, Reinaldo M. Palhares, Fabiano S. Moreira, André P. Lemos

Departamento de Engenharia Eletrônica, UFMG

{caminhas,palhares,fabiano,lemos}@cpdee.ufmg.br

Resumo – Este estudo apresenta uma abordagem para detecção de falhas em sistemas dinâmicos baseada em uma formulação neural/fuzzy/Bayesiana para detecção de pontos de mudança em séries temporais. A falha é detectada, contanto que caracterize a ocorrência de um ponto de mudança na série temporal. A metodologia é aplicada na detecção de falhas em um sistema de tanques interativos.

Palavras-chave – Detecção de falhas, redes neurais, sistemas *fuzzy*, abordagem *bayesiana*.

Abstract – This study presents an approach for fault detection in dynamical systems which is based neural/fuzzy/Bayesian formulation for change points detection in time series. The fault is detected as long as it characterizes a change point in the time series. The methodology is applied to fault detection in an interactive system of tanks.

Keywords – Fault detection, neural networks, fuzzy systems, bayesian approach.

1. INTRODUÇÃO

Atualmente há uma crescente demanda para uma detecção segura de falhas em sistemas dinâmicos representando processos reais, pois a detecção antecipada de falhas permite um alto grau de confiabilidade ao funcionamento dos mesmos, evitando uma eventual parada de produção, perda material, qualidade na produção e até mesmo acidentes envolvendo seres humanos. Essa demanda resultou na necessidade de sistemas de supervisão (Figura 1) que integram os sistemas FDI (Fault Detection and Isolation) nos processos.

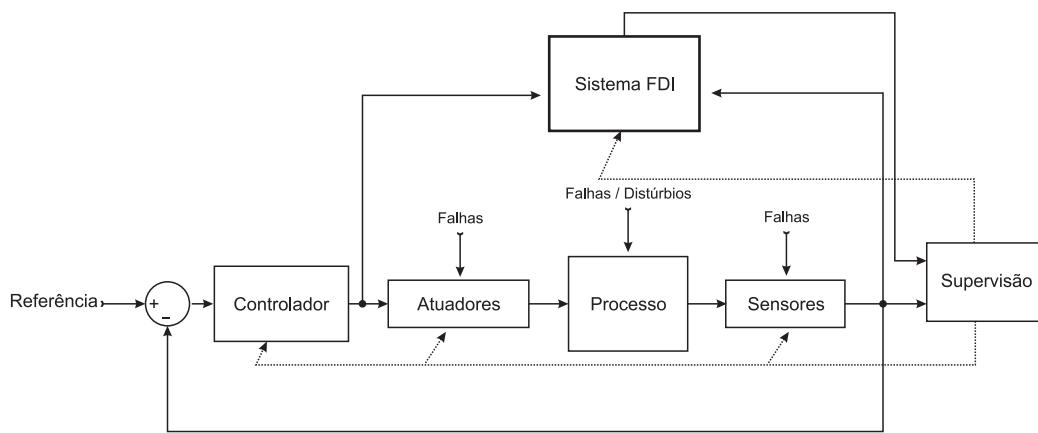


Figura 1: Supervisão de processos industriais com integração de sistema FDI

Um sistema FDI tem como objetivo principal o reconhecimento do comportamento anormal (falhas) dos componentes de um processo, ou do próprio processo, através do monitoramento de suas variáveis. A primeira etapa de um sistema FDI é a detecção de falhas, que será a motivação do trabalho.

A literatura apresenta diversas classes de estratégias que tratam o problema FDI [1] [2]. Essas estratégias podem ser, em geral, divididas em abordagens baseadas em modelos quantitativos [3] e em modelos qualitativos [4], [5].

A maioria das abordagens quantitativas baseia-se em modelos matemáticos da planta. Muitos artigos, com diferentes abordagens baseadas em modelos trataram de FDI nos últimos anos. As principais abordagens nesse contexto são baseadas em observadores (com entradas desconhecidas) [1], [6], [7], [8], [9], relações de paridade [10], [11], [1] e filtros de Kalman e \mathcal{H}_∞ [12], [1]. A necessidade do modelo matemático da planta pode levar a várias dificuldades na implementação destas abordagens, por exemplo, fatores como a complexidade sistema, não-linearidades e incertezas paramétricas.

Por outro lado, a maioria das abordagens qualitativas baseia-se no conhecimento de alguns padrões históricos de funcionamento processo. As principais abordagens qualitativas são: SDG (Signed Directed Graph) [13], árvore de falhas [14], sistemas fuzzy [15], análise qualitativa de tendências [16] e redes neurais [17], [18] (a rede neural também pode ser usada como observador [19]). No geral, todas as abordagens qualitativas e quantitativas descritas anteriormente utilizam algum tipo de especificação de limiar para detectar falha.

Todos estes aparatos de técnicas para detecção de falhas são eficientes em alguns problemas e ineficientes em outros, como discutido anteriormente. Neste trabalho será proposto o uso da associação de técnicas baseadas em redes neurais, conjuntos fuzzy e estatística bayesiana para detectar falhas em um sistema de tanques iterativos, como um problema de detecção de pontos de mudança. Este sistema de tanques iterativos foi proposto em [20] como um possível *benchmark* para detecção de falhas em sistemas dinâmicos e está disponibilizado em [21].

2. ABORDAGEM NEURAL/FUZZY/BAYESIANA PARA DETECÇÃO DE PONTO DE MUDANÇA

2.1 1^a Etapa: Transformação da Série Temporal através da Teoria dos Conjuntos Fuzzy

Esta etapa consiste em usar a teoria dos conjuntos fuzzy [22] para transformar uma dada série temporal em outra com distribuição beta. Esta transformação nos permite obter um modelo fixo a ser usado na 2^a etapa. Para ilustrar como isso é feito, a seguinte série temporal será usada:

$$y(t) = \begin{cases} p_1 + 0.1 * \epsilon(t) + 0.1 * \epsilon(t-1), & \text{se } t \leq m, \\ p_2 + 0.1 * \epsilon(t) + 0.1 * \epsilon(t-1), & \text{se } t > m \end{cases} \quad (1)$$

sendo p_1 o 1º ponto de operação, p_2 o 2º ponto de operação, $\epsilon(t)$ é um sinal de ruído com distribuição $\pi(\cdot)$ e m é o ponto de mudança. A Figura 2 mostra a série temporal com $p_1 = 1$, $p_2 = 2$, $\epsilon(t) \sim U(0, 1)$ (distribuição uniforme no intervalo $[0, 1]$), $m = 30$ e 60 amostras.

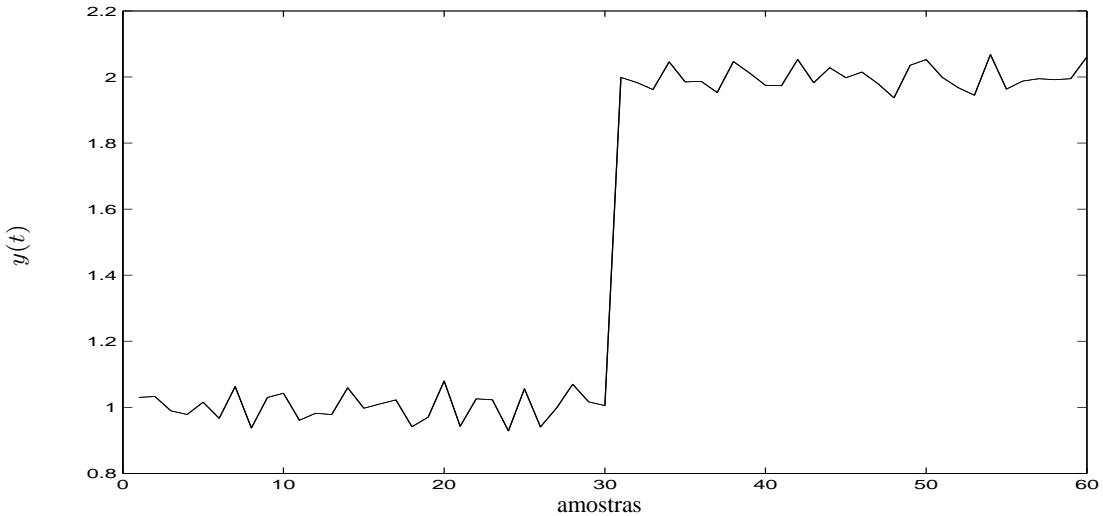


Figura 2: Série temporal com $p_1 = 1$, $p_2 = 2$, $\epsilon(t) \sim U(0, 1)$, $m = 30$ e 60 amostras.

A aglomeração fuzzy proposta para transformar uma dada série temporal em outra com distribuição beta é descrita a seguir:

1. Entre com a série temporal $y(t)$;
2. Encontre C_i , $i = 1, 2$, os centros de cada aglomerado para $y(t)$ (nesse trabalho usou-se a rede neural de Kohonen [23]), como ilustrado na Figura 3, considerando a série temporal em (1).
3. Calcule o grau de pertinência fuzzy dado por $\mu_i(t) \triangleq 1 - \frac{(y(t)-C_i)^2}{\sum_{i=1}^k(y(t)-C_i)^2}$, para cada amostra da série temporal, $y(t)$, para cada centro C_i (como ilustrado na Figura 4, considerando a série temporal em (1)).

Considerando a série temporal $y(t)$ em (1), a Figura 5 ilustra o histograma de $\mu_1(t)$ para $t \leq 30$ (antes do ponto de mudança) e o histograma de $\mu_1(t)$ para $t > 30$ (depois do ponto de mudança). Além disso, é evidente que a distribuição de $\mu_1(t)$ é confinada em $[0, 1]$:

- se $y(t) \rightarrow C_1$ então $\mu_1(t) \rightarrow 1^-$
- se $y(t) \rightarrow C_2$ então $\mu_1(t) \rightarrow 0^+$
- se $C_1 \rightarrow C_2$ então $\mu_1(t) \rightarrow \frac{1}{2}$
- se $y(t) \subset [C_1, C_2]$ então $\mu_1(t) \subset [0, 1]$

e, usando a divergência de Kullback-Leibler [24], conclui-se que as distribuições de $\mu_1(t)$ seguem uma família de distribuições beta com diferentes parâmetros de entrada: para $t \leq 100$, obtém-se uma distribuição beta(a,b), ou uma distribuição beta(c,d) se $t > 100$.

A técnica de aglomeração garante que a distribuição de $\mu_1(t)$ terá sempre uma distribuição de probabilidade fixa, fazendo com que a formulação Bayesiana tenha sempre o mesmo modelo para detecção de pontos de mudança. Neste artigo será usado o algoritmo Metropolis-Hastings para detecção de pontos de mudança, uma vez que é uma estratégia simples e poderosa.

2.2 2^a Etapa: Formulação do Algoritmo Metropolis-Hastings

O objetivo do algoritmo de Metropolis-Hastings [25] é construir uma cadeia de Markov com uma específica distribuição de equilíbrio π .

Suponha que a cadeia esteja no estado x e um valor x' é gerado de uma distribuição proposta $q(\cdot | x)$ (candidato a ser aceita). Note que a distribuição proposta pode depender do estado atual da cadeia, por exemplo, $q(\cdot | x)$ poderia ser uma distribuição normal centrada em x . O novo valor x' é aceito com probabilidade:

$$\alpha(x, x') = \min \left(1, \frac{\pi(x') q(x, x')}{\pi(x) q(x', x)} \right) \quad (2)$$

onde α é a distribuição de interesse.

Uma característica importante é que só é preciso conhecer α parcialmente, i.e., a menos de uma constante, já que neste caso a probabilidade (2) não se altera. Isso é fundamental em aplicações Bayesianas onde não se conhece completamente a posteriori.

Em termos práticos, o algoritmo de Metropolis-Hastings pode ser especificado pelos seguintes passos:

1. Inicialize o contador de iterações $t = 0$ e especifique um valor inicial x^0 ;
2. Gere um novo valor x' da distribuição $q(\cdot, x)$;
3. Calcule a probabilidade de aceitação $\alpha(x, x')$ e gere $u \sim U(0, 1)$;
4. Se $u \leq \alpha$ então aceite o novo valor e faça $x^{t+1} = x'$, caso contrário rejeite e faça $x^{t+1} = x^t$;
5. Incremente o contador de t para $(t + 1)$ e volte ao passo 2 até o número de iterações especificadas.

Note que, como discutido na seção anterior, a 1^a etapa da metodologia gera uma série temporal com as seguintes distribuições:

$$y(t) \sim \text{beta}(a, b), \text{ para } t = 1, \dots, m \\ y(t) \sim \text{beta}(c, d), \text{ para } t = m + 1, \dots, n$$

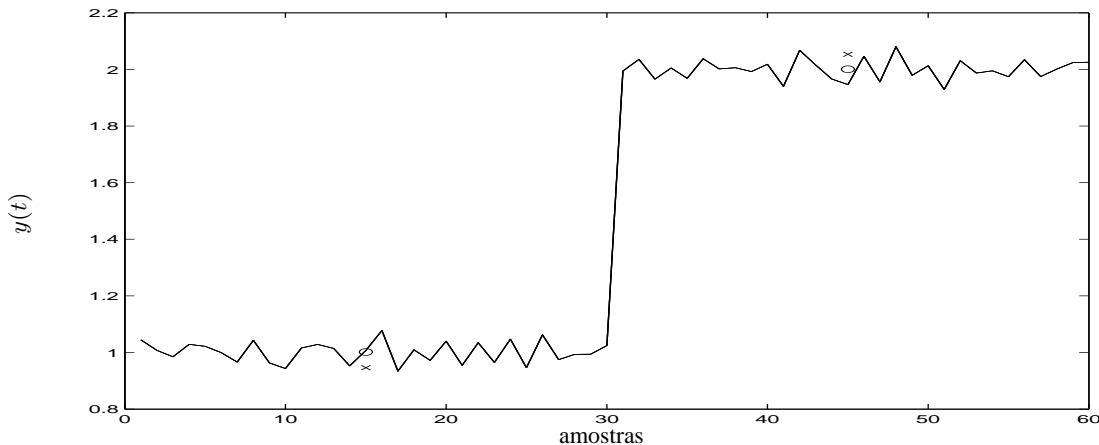


Figura 3: Centros da série temporal: ‘x’ denota $\min\{y(t)\}$ e $\max\{y(t)\}$ e ‘o’ denota os centros encontrados pela rede de Kohonen.

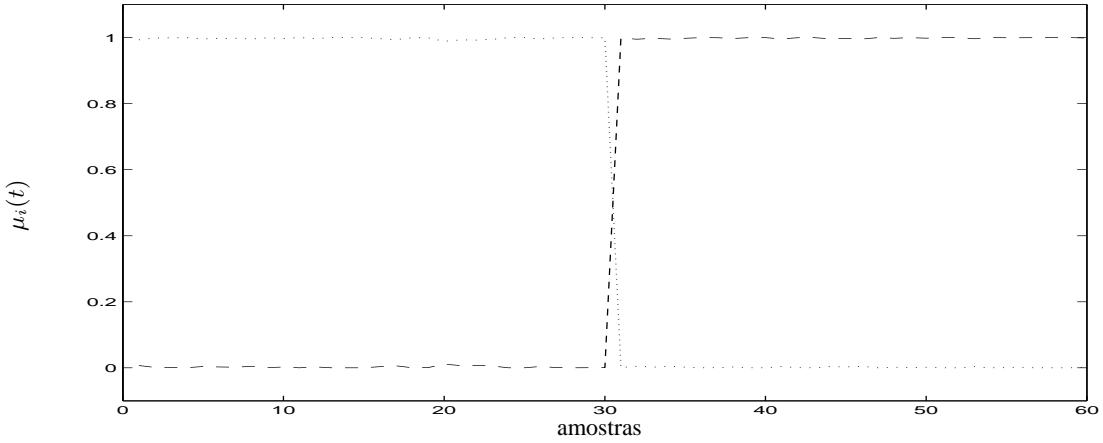


Figura 4: $\mu_1(t)(\dots)$ e $\mu_2(t)(- - -)$.

Os parâmetros a serem estimados pelo algoritmo Metropolis-Hastings são a, b, c, d e o ponto de mudança m . Neste tipo de algoritmo, a escolha de *prioris* pouco informativas são usuais como, por exemplo:

$$\begin{aligned} a &\sim \text{gamma}(0.1, 0.1) \\ b &\sim \text{gamma}(0.1, 0.1) \\ c &\sim \text{gamma}(0.1, 0.1) \\ d &\sim \text{gamma}(0.1, 0.1) \\ m &\sim U\{1, 2, \dots, n\}, \text{ com } p(m) = \frac{1}{n} \end{aligned}$$

Essas distribuições, com parâmetros 0.1, foram escolhidas por serem pouco informativas fazendo com que o espaço paramétrico seja completamente varrido.

O ponto de mudança é detectado como sendo o maior valor de massa do histograma de m , com exceção das bordas. Como ilustração, e considerando somente uma simulação, a Figura 6 ilustra o resultado da metodologia proposta para $p_1 = 1, p_2 = 2, e(t) \sim U(0, 1)$, e $m = 30$.

3. APLICAÇÃO NA DETECÇÃO DE FALHAS EM UM SISTEMA DE TANQUES INTERATIVOS

O modelo matemático do sistema de tanques interativos é obtido a partir do balanço de massa entre os tanques TQ-2 e TQ-3 e utilizando a Lei de Bernoulli [20]. Tomando-se: $x_1 = h_2, x_2 = h_3, y_1 = h_3, y_2 = q_o$ e $y_3 = q_i$, o modelo do sistema é dado por:

$$\begin{cases} \dot{x}_1 = \frac{1}{A} [q_1(R_1, u_1, p_1) - q_{23}(x_1, x_2)] \\ \dot{x}_2 = \frac{1}{A} [q_{23}(x_1, x_2) - q_o(R_2, u_2, p_2)] \end{cases} \quad (3)$$

$$\begin{cases} y_1 = x_2 \\ y_2 = q_o(R_2, u_2, p_2) \end{cases} \quad (4)$$

$$\begin{cases} q_i(R_1, u_1, p_1) = Qimax \cdot q_f(R_1, u_1, p_1) \\ q_o(R_2, u_2, p_2) = Qomax \cdot q_f(R_2, u_2, p_2) \\ q_{23}(x_1, x_2) = \frac{\sqrt{x_1 - x_2}}{R_h} \end{cases} \quad (5)$$

a expressão usada para calcular a vazão q_f foi:

$$q_f(R_i, u_i, p_i) = \frac{1}{\sqrt{1 + (\frac{1}{R_i^{2(u_i-1)}} - 1) \cdot p_i}} \quad (6)$$

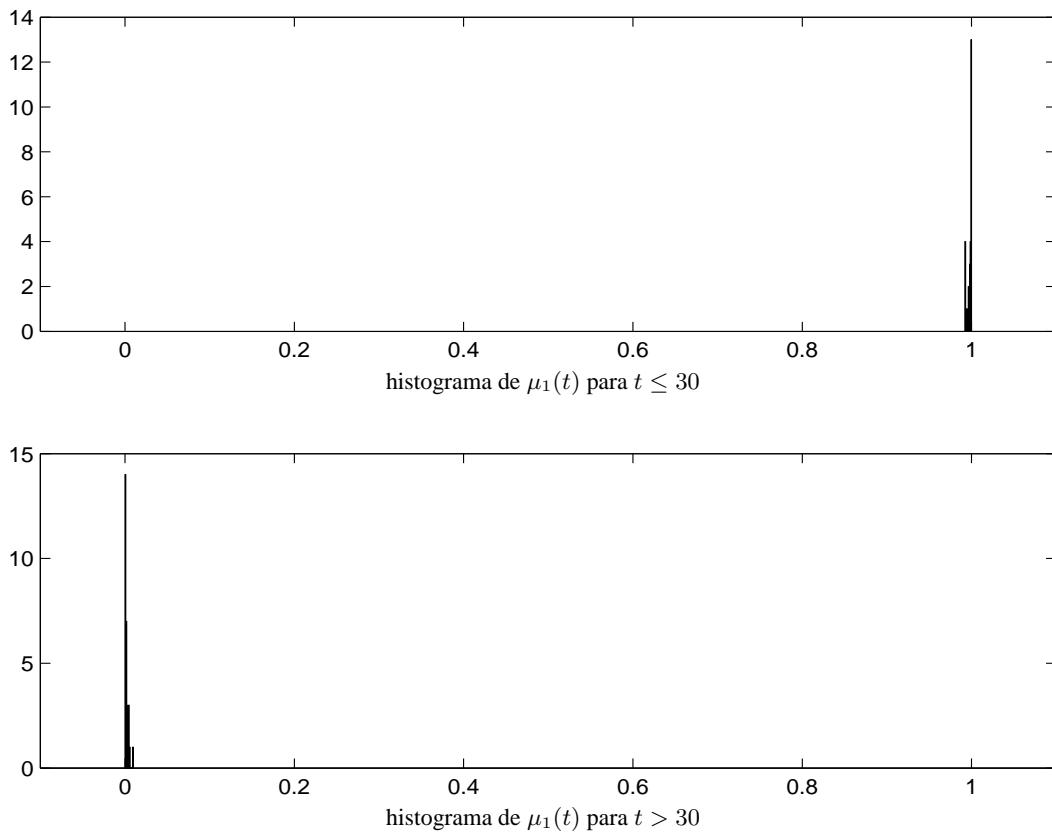


Figura 5: histogramas de $\mu_1(t)$.

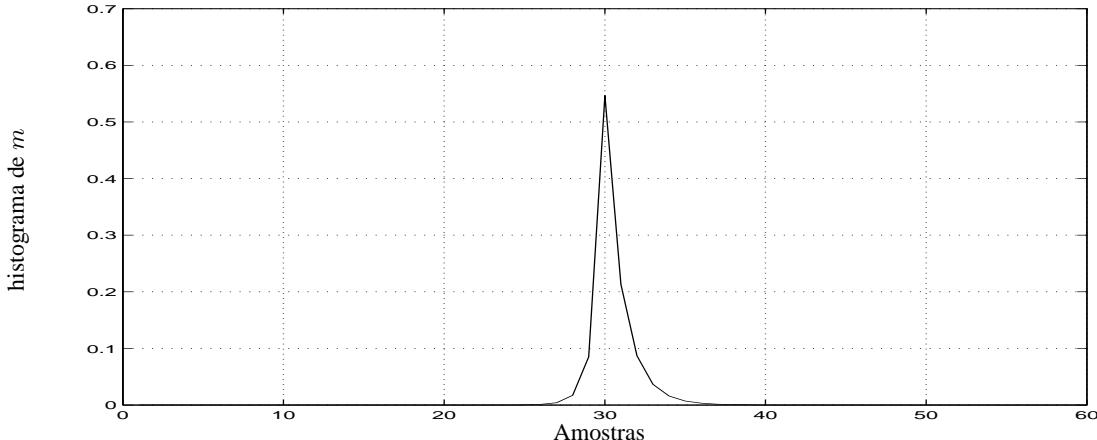


Figura 6: Resultado da metodologia proposta para $p_1 = 1$, $p_2 = 2$, $e(t) \sim U(0, 1)$, e $m = 30$.

sendo:

- $q_o(R_2, u_2, p_2)$: vazão de saída do tanque TQ-3, em m^3/s ;
- $q_i(R_1, u_1, p_1)$: vazão de entrada do tanque TQ-2, em m^3/s ;
- $q_{23}(x_1, x_2)$: vazão entre os tanques TQ-2 e TQ-3, em m^3/s ;
- $q_f(R_i, u_i, p_i)$: vazão fracionária da válvula "i";
- Q_{imax} : vazão máxima de entrada do tanque TQ-2, em m^3/s ;
- Q_{omax} : vazão máxima de saída do tanque TQ-3, em m^3/s ;
- A: área da base dos tanques TQ-2 e TQ-3;
- R_1 : representa o alcance da válvula FCV-1;
- R_2 : representa o alcance da válvula FCV-2;

p_1 : razão entre a queda de pressão mínima e máxima da válvula FCV-1;

p_2 : razão entre a queda de pressão mínima e máxima da válvula FCV-2;

R_h : resistência hidráulica do duto entre os tanques;

u_1 : sinal de controle fracionário da válvula FCV-1;

u_2 : sinal de controle fracionário da válvula FCV-2;

A modelagem das possíveis falhas no sistema, tais como falhas dos atuadores (válvulas FCV-1 e FCV-2 e nas bombas BA-1 e BA-2); falhas nos componentes do sistema (entupimentos e vazamentos nos dutos de conexão entre tanques) e falhas de instrumentação (sensores de vazão e nível), foi mostrada em [20]. Neste trabalho serão consideradas apenas falhas de instrumentação.

As variáveis de saída y_2 e y_3 são medidas utilizando sensores de vazão do tipo turbina e y_1 sensor de nível tipo célula de carga. Para estes sensores foram consideradas somente falhas bruscas. No caso do sensor de nível, falhas bruscas podem ser causadas pela queda da linha de transmissão do sinal para o PLC ou pela desconexão do tubo de ar da capsula da célula de carga. Já as falhas bruscas dos sensores de vazão podem ocorrer pela queda da linha de transmissão do sinal, pelo agarramento da turbina ou mesmo pela obstrução do feixe de luz infravermelho usado na medição.

Estas falhas podem ser modeladas da seguinte forma:

$$\begin{cases} \dot{x}_1 = \frac{1}{A}[q_i(R_1, u_1, p_1) - q_{23}(x_1, x_2)] \\ \dot{x}_2 = \frac{1}{A}[q_{23}(x_1, x_2) - q_o(R_2, u_2, p_2)] \end{cases} \quad (7)$$

$$\begin{cases} y_1 = k_{fy1} \cdot x_2 \\ y_2 = k_{fy2} \cdot q_o(R_2, u_2, p_2) \\ y_3 = k_{fy3} \cdot q_i(R_1, u_1, p_1) \end{cases} \quad (8)$$

sendo

$k_{fy1} \in \{0, 1\}$ indica falha no sensor de nível;

$k_{fy2} \in \{0, 1\}$ indica falha no sensor de vazão de saída;

$k_{fy3} \in \{0, 1\}$ indica falha no sensor de vazão de entrada;

Para estes parâmetros o valor “0” indica a falha.

A Figura 7 indica o nível do tanque TQ-3 quando ocorre falha no sensor de nível no instante $t = 2000s$.

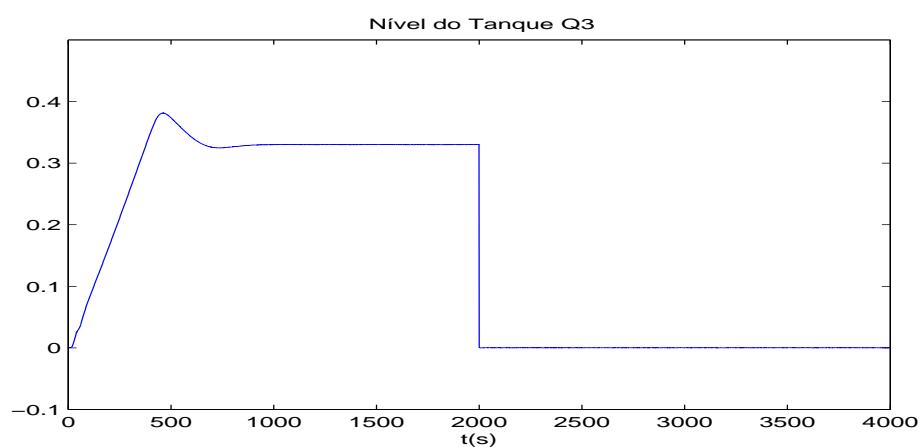


Figura 7: Nível do tanque TQ-3 com falha no sensor de nível no instante $t = 2000s$

A Figura 8 ilustra na sua parte superior o nível do tanque TQ-3 (linha mais fina) e uma janela desta variável (linha mais grossa), compreendendo o instante onde ocorre a mudança da variável, indicando assim uma falha. A parte inferior da Figura 8, ilustra o resultado da metodologia proposta, indicando um ponto de mudança no instante $t = 2000s$.

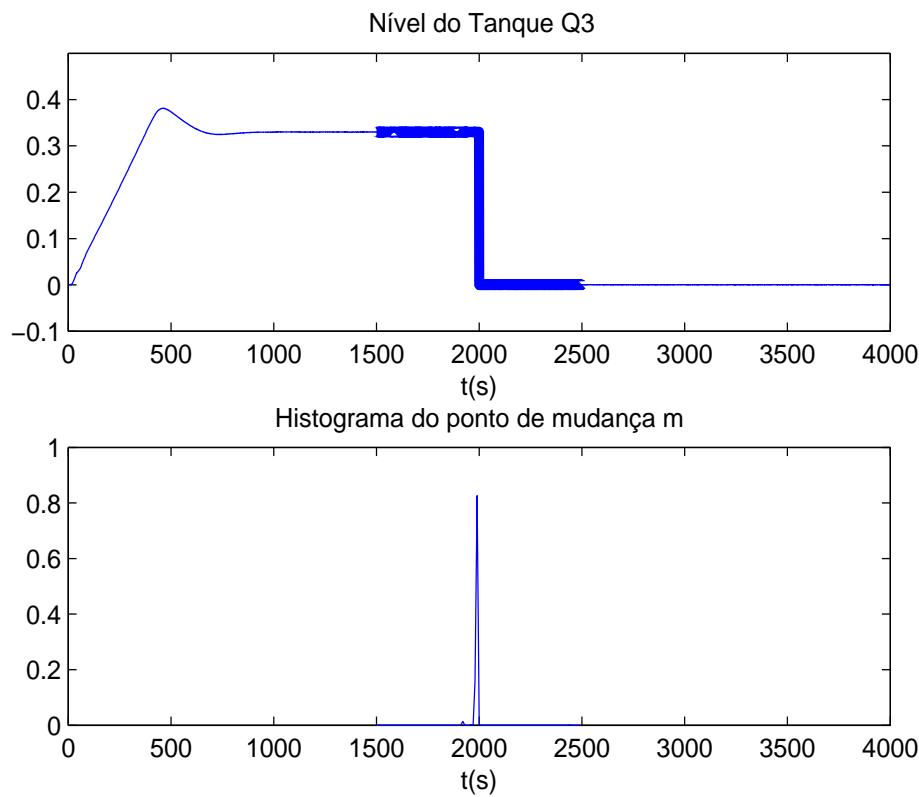


Figura 8: Resultado da metodologia proposta.

4 CONCLUSÕES

Neste artigo uma nova metodologia fuzzy/Bayesiana para detecção de pontos de mudança em séries temporais foi utilizado para tratar o problema na detecção de falhas incipientes em sistemas dinâmicos. A metodologia proposta tem como vantagens, em comparação com outras técnicas de FDI, não requerer modelo matemático, especificação de limiares e algum grau de conhecimento prévio do comportamento do sistema dinâmico. A metodologia é baseada numa formulação de duas etapas. Na primeira etapa, uma rede neural de Kohonen e a teoria dos conjuntos fuzzy são aplicadas na série temporal com o objetivo de aglomerar e transformar os dados iniciais, com distribuição arbitrária, em dados que podem ser aproximados por uma distribuição beta. A segunda etapa consiste em usar análise Bayesiana (o algoritmo de Metropolis-Hastings) para detectar pontos de mudança na série temporal transformada, isto é, com características estatísticas fixas. Essa formulação de duas etapas permite uma sistemática eficiente para resolver o problema de detecção de ponto de mudança, que é utilizado para detectar falhas, as quais podem ser caracterizadas como mudanças em sinais do sistema dinâmico. Esta metodologia foi aplicada com sucesso para o problema de detecção de falhas de instrumentação no sistema de tanques interativos disponível em [21].

REFERÊNCIAS

- [1] J. Chen and R. J. Patton. *Robust model-based fault diagnosis for dynamic systems*. Dordrecht: Kluwer Academic Publishers, 1999.
- [2] M. F. S. V. D'Angelo, R. M. Palhares, W. M. Caminhos, R. H. C. Takahashi, R. D. Maia, A. P. Lemos and M. J. Inácio. “Detecção de falhas: uma revisão com aplicações”. *Tutorias do CBA*, 2010.
- [3] V. Venkatasubramanian, R. Rengaswamy, K. Yin and S. N. Kavuri. “A review of process fault detection and diagnosis – Part I: Quantitative model-based methods”. *Computers and Chemical Engineering*, vol. 27, pp. 293–311, 2003.
- [4] V. Venkatasubramanian, R. Rengaswamy and S. N. Kavuri. “A review of process fault detection and diagnosis – Part II: Qualitative models and search strategies”. *Computers and Chemical Engineering*, vol. 27, pp. 313–326, 2003.
- [5] V. Venkatasubramanian, R. Rengaswamy, S. N. Kavuri and K. Yin. “A review of process fault detection and diagnosis – Part III: Process history based methods”. *Computers and Chemical Engineering*, vol. 27, pp. 327–346, 2003.

- [6] W. M. Caminhas and R. H. C. Takahashi. “Dynamic system failure detection and diagnosis employing sliding mode observers and fuzzy neural networks”. In *Proceedings of the Joint 9th IFSA and 20th NAFIPS*, pp. 304–309, Vancouver, 2001.
- [7] R. H. C. Takahashi and P. L. D. Peres. “Unknown input observers for uncertain systems: A unifying approach”. *European Journal of Control*, vol. 5, no. 2–4, pp. 261–275, 1999.
- [8] R. H. C. Takahashi, R. M. Palhares and P. L. D. Peres. “Discrete-time Singular Observers: $\mathcal{H}_2/\mathcal{H}_\infty$ Optimality and Unknown Inputs”. *International Journal of Control*, vol. 72, no. 6, pp. 481–492, 1999.
- [9] V. Puig, A. Stancu, T. Escobet, F. Nejjari, J. Quevedo and R. Patton. “Passive robust fault detection using interval observers: Application to the DAMADICS benchmark problem”. *Control Engineering Practice*, vol. 14, no. 6, pp. 621–633, 2006.
- [10] S. Ploix and O. Adrot. “Parity relations for linear uncertain dynamic systems”. *Automatica*, vol. 42, no. 9, pp. 1553–1562, 2006.
- [11] J. Gertler. “Fault detection and isolation using parity relations”. *Control Engineering Practice*, vol. 5, no. 5, pp. 653–661, 1997.
- [12] A. Zolghadri. “An algorithm for real-time failure detection in Kalman filters”. *IEEE Transactions on Automatic Control*, vol. 41, no. 10, pp. 1537–1539, 1996.
- [13] M. R. Maurya, R. Rengaswamy and V. Venkatasubramanian. “A signed directed graph-based systematic framework for steady-state malfunction diagnosis inside control loops”. *Chemical Engineering Science*, vol. 61, no. 6, pp. 1790–1810, 2006.
- [14] Y. Dutuit and A. Rauzy. “Approximate estimation of system reliability via fault trees”. *Reliability Engineering & System Safety*, vol. 87, no. 2, pp. 163–172, 2005.
- [15] S. M. El-Shal and A. S. Morris. “A fuzzy expert system for fault detection in statistical process control of industrial processes”. *IEEE Transactions on Systems, Man and Cybernetics, Part C*, vol. 30, no. 2, pp. 281–289, 2000.
- [16] M. R. Maurya, R. Rengaswamy and V. Venkatasubramanian. “Fault diagnosis using dynamic trend analysis: A review and recent developments”. *Engineering Applications of Artificial Intelligence*, vol. 20, no. 2, pp. 133–146, 2007.
- [17] J. M. F. Calado, J. Korbicz, K. Patan, R. J. Patton and J. M. G. S. da Costa. “Soft computing approaches to fault diagnosis for dynamic systems”. *European Journal of Control*, vol. 7, no. 2–3, pp. 248–286, 2001.
- [18] M. F. S. V. D’Angelo and P. P. Costa. “Detection of shorted turns in the field winding of turbogenerators using the neural network MLP”. In *Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics*, pp. 1930–1935, Tucson, 2001.
- [19] F. J. Uppal, R. J. Patton and M. Witczak. “A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the DAMADICS benchmark problem”. *Control Engineering Practice*, vol. 14, no. 6, pp. 699–717, 2006.
- [20] W. M. Caminhas. “Estratégias de Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos”. Ph.D. thesis, Universidade Estadual de Campinas, UNICAMP, Brasil, 1997.
- [21] M. F. S. V. D’Angelo. “Iterative tanks system by fault simulation”. <http://www.dcc.unimontes.br/~dangelo/benchmark.rar>, 2011.
- [22] L. A. Zadeh. “Fuzzy Sets”. *Information and Control*, vol. 8, no. 3, pp. 338–353, 1965.
- [23] T. Kohonen. *Self-organizing maps*. Springer Series in Information Sciences. Springer, 2001.
- [24] S. Kullback and R. A. Leibler. “On Information and Sufficiency”. *Annals of Mathematical Statistics*, vol. 22, no. 1, pp. 79–86, 1951.
- [25] D. Gamerman. *Markov chain Monte Carlo: stochastic simulation for Bayesian inference*. Chapman & Hall, 1997.