

DETECÇÃO DE FALHAS EM SISTEMAS DINÂMICOS COM AGRUPAMENTO NEURAL EMPREGANDO MAPAS DE KOHONEN

JACKSON P. MATSUURA, TAKASHI YONEYAMA, ROBERTO K. H. GALVÃO, MONAEL P. RIBEIRO

*Divisão de Engenharia Eletrônica – IEE
Instituto Tecnológico de Aeronáutica - ITA*

*Praça Marechal Eduardo Gomes, 50 – Vila das Acácias – São José dos Campos – 12.228-900 - SP
E-mails: jackson@ita.br, takashi@ita.br, kawakami@ita.br, monael@ita.br*

Abstract— The prompt detection of faults in dynamic systems is essential for the prevention of dangerous operation conditions and physical damage of the system, which would put at risk valuable resources, vital equipment and human lives. The conventional fault detection methods, however, present difficulties associated to physical space, nonexistence of an accurate mathematical model of the system and unavailability of data of the system operating under faults, among others. In this work a new method of Fault Detection in Dynamic Systems without those limitations is proposed. In the proposed approach a Artificial Neural Network using Kohonen maps is used in the unsupervised pattern learning from values of the system operating without faults. The result of neural network training are used to verify if the behavior learned as normal is keep. The results obtained with the new method are compared with those obtained with the use of a method based on analytical redundancy, showing that the method is very promising.

Keywords— Fault Detection, Machine Learning, Clusterization, Artificial Neural Networks, Kohonen Maps

Resumo— A pronta detecção da ocorrência de falhas em sistemas dinâmicos é essencial na prevenção de condições de operação perigosas e mesmo de avaria física do sistema, o que colocaria em risco recursos valiosos, equipamento vital e vidas humanas. Os métodos convencionais de detecção de falhas, porém, esbarram em limitações de espaço físico, ausência de um modelo matemático acurado do sistema e indisponibilidade de dados sobre o comportamento do sistema operando com falhas, entre outros. Nesse trabalho é proposto um novo método de Detecção de Falhas em Sistemas Dinâmicos que não apresenta essas limitações. Na abordagem proposta uma Rede Neural Artificial usando mapas de Kohonen é empregada na aprendizagem não supervisionada de padrões, a partir de valores do sistema operando sem falhas. Os pesos dos neurônios resultantes dos treinamentos da rede neural são utilizados para verificar se o comportamento aprendido como normal se mantém. Os resultados obtidos com o novo método são comparados aos obtidos com a utilização de um método baseado em redundância analítica, mostrando-se bastante promissores.

Palavras-chave— Detecção de Falhas, Aprendizagem, Clusterização, Redes Neurais Artificiais, Mapas de Kohonen

1 Introdução

Em sentido amplo, uma falha pode ser interpretada como uma mudança inesperada no comportamento de um sistema (Sousa et. al., 2000). A pronta detecção de tal ocorrência pode ser essencial para impedir uma maior deterioração do sistema, o que poderia conduzir as condições de operação perigosas e mesmo a avaria física, pondo em risco recursos valiosos, equipamento vital e vidas humanas.

Processos químicos, reatores nucleares, sistemas de transporte coletivo e veículos aeroespaciais são exemplos de sistemas dinâmicos onde uma falha não detectada pode conduzir a conseqüências econômicas, ambientais e sociais desastrosas (Frisk, 1993; Sorsa et. al., 1991 e Vemuri et. al., 2001).

Especialmente na área aeroespacial (Patton & Chen, 1992; Aravena & Chowdhury, 2001; Hush et. al., 1997; Yairi et. al., 2001 e Wilson et. al., 2002), uma falha não detectada pode conduzir a conseqüências gravíssimas. Uma única falha pode custar uma estação espacial inteira, uma nave espacial, uma aeronave ou um foguete.

A tendência na automação de um número cada vez maior de sistemas e o crescente aumento da complexidade desses sistemas, aliados a uma cres-

cente demanda por tolerância a falhas, eficiência, confiabilidade e segurança, têm estimulado muito o desenvolvimento da área de detecção de falhas.

Durante as últimas três décadas várias abordagens referentes à detecção de falhas foram relatadas. Parte do esforço nessa área pode ser visto nos trabalhos de Angeli e Chatzinikolau (2004), Basseville e Nikiforov (1993), Chen e Patton (1999), Fenton, McGinnity e Maguire (2001), Gertler (1998), Patton, Frank e Clark (1989); (2000) e Vankatasubramanian et. al. (2003a); (2003b); (2003c).

2 Métodos de Detecção de Falhas

As primeiras técnicas de detecção de falhas baseavam-se principalmente em redundância física, ou seja, na comparação de sinais medidos por sensores redundantes. A partir da década de 70, com os avanços tecnológicos, foi introduzido o paradigma da redundância analítica, onde um modelo do sistema é utilizado para gerar sinais redundantes que são comparados aos medidos pelos sensores físicos (Persin et. al., 2002).

O custo de sensores redundantes e a necessidade de um modelo muito próximo da realidade, porém torna essas duas abordagens ineficazes em alguns casos.

Nos últimos anos, graças novamente aos avanços tecnológicos, novos métodos e técnicas sem essas limitações vêm sendo propostos e estudados, como por exemplo, o uso de redes Bayesianas construídas a partir de conhecimento de especialistas (Lerner et. al., 2000); (Mehranbod, 2002) e o treinamento de redes Neurais Artificiais e de redes Bayesianas a partir de dados do sistema operando normalmente e na presença de falhas (Fortuna et. al., 1999; Jakubek & Strasser, 2002; Hush et. al., 1997; Sorsa et. al., 1991; Baccharini et. al., 2003; Furtado et. al. 2005; Chien et. al., 2002; Santoso et. al., 1999 e Riascos et. al., 2005). Em ambos os casos não há necessidade de espaço adicional para os sensores redundantes nem de um modelo do sistema para a geração de sinais redundantes. A limitação desses métodos, porém, reside no fato dos mesmos dependerem de conhecimento prévio das possíveis falhas e de suas conseqüências imediatas. Tal informação nem sempre está disponível, especialmente em sistemas críticos, como aeronaves, usinas nucleares, processos químicos de alto custo, onde muitas vezes não existem dados de nenhuma operação com falhas.

Uma alternativa a essa falta de informação sobre falhas é a aprendizagem do comportamento normal do sistema, que pode ser comparada com o resultado de uma reaprendizagem a partir do sistema em funcionamento. Divergências nos resultados da aprendizagem são indicadores de falha no sistema (Caminhas et. al., 2001; Mok & Chan, 2005). O comportamento aprendido como normal pode também ser usado para uma verificação do comportamento atual do sistema, ao invés da utilização de uma reaprendizagem (Freitas et. al., 2005; Matsuura & Yoneyama 2004a; 2004b). Alguns métodos de aprendizagem e algumas verificações são porém bastante custosas do ponto de vista de tempo de processamento, o que pode limitar seu uso em sistemas com constantes de tempo muito rápidas.

Nesse trabalho é proposto um novo método de detecção de falhas em sistemas dinâmicos, baseado na criação de agrupamentos a partir de dados do sistema operando normalmente, com o uso de uma rede Neural Artificial utilizando mapas de Kohonen. (Duda et. al., 2001; Nascimento Jr. & Yoneyama, 2000).

3 Solução Proposta

Nesse trabalho um novo método de detecção de falhas em sistemas dinâmicos, baseado na aprendizagem a partir do sistema operando sem falhas e na verificação desse comportamento, é apresentado.

Neste método uma rede Neural empregando mapas de Kohonen é treinada a partir dos dados do sistema operando sem falhas. A rede cria agrupamentos para todos os dados apresentados obtendo os pesos de seus neurônios.

O emprego dos mapas de Kohonen pode não vir a representar um agrupamento, ou seja, alguns neu-

rônios que compõem a rede podem jamais terem sido vencedores para todo o conjunto de treinamento e, portanto, não corresponderiam a uma situação de operação normal do sistema.

Para que os vetores de medidas próximos aos pesos dos neurônios que representam comportamento falho não venham a ser confundidos com os neurônios que indicam comportamento normal do sistema, é preciso rotulá-los como sendo de operação falha, ou seja, esses neurônios serão representantes de um agrupamento que simboliza falhas no sistema.

Desse modo, antes de ser verificada a proximidade de um conjunto de medidas ao neurônio vencedor, verifica-se se esse neurônio representa um agrupamento de falha, um alarme é acionado, senão verifica-se se a distância entre o vetor de medidas e o vetor representado pelos pesos do neurônio é maior ou menor que o limiar de proximidade.

Para um melhor entendimento desse método de detecção de falhas utilizando mapas de Kohonen, um exemplo artificial de duas dimensões será utilizado.

As duas variáveis do sistema de exemplo são x e y . As Figuras 1, 2 e 3 ilustram a utilização dos mapas de Kohonen na detecção de falhas. Nesse exemplo foram utilizados 5x5 neurônios.




Figura 1. Vetores de treinamento e rede de Kohonen obtida, bem como neurônios válidos.

A Figura 1 apresenta a rede de Kohonen após o treinamento. Na Figura 1 também são mostrados – em destaque – os neurônios rotulados como válidos. Os segmentos de reta representam as relações de vizinhança entre os neurônios da rede de Kohonen.

A Figura 2 apresenta três pontos que teriam sido medidos do sistema operando em estado de falha. As ligações entre os neurônios no mapa de Kohonen e as circunferências de raio igual ao limiar de proximidade foram omitidas por conveniência de visualização. Nesse caso o ponto f_1 seria erroneamente considerado como de operação normal, por estar próximo a um neurônio rotulado como normal. Já o ponto f_2 seria considerado como indicativo de falha por estar mais distante que o limiar de proximidade do

neurônio vencedor. Finalmente, o ponto f_3 seria considerado




Figura 2. Exemplo de vetores de operação com falhas f_1 , f_2 e f_3 .

como indicativo de falha por estar mais próximo de um neurônio que não foi rotulado como normal.




Figura 3. Exemplo de vetores de operação normal n_1 , n_2 e n_3 .

Agora a Figura 3 apresenta três pontos que teriam sido considerados em condições normais de operação no processo de medição. O ponto n_1 seria corretamente considerado como normal por estar próximo a um neurônio rotulado como normal; já os pontos n_2 e n_3 iriam causar falsos alarmes, pois n_2 estaria mais distante do que o limiar de proximidade do neurônio mais próximo e n_3 seria associado a um neurônio não rotulado como válido.

4 Simulações

4.1 Exemplo de Aplicação

Para ilustrar a técnica proposta, utilizou-se o servomecanismo de velocidade adotado em Souza et. al. (2000), Paiva (2003) e Matsuura & Yoneyama (2004a; 2004b), cuja função de transferência entre o sinal de entrada u e velocidade do eixo do servo y é dada pela equação 1:

$$G(s) = \frac{Y(s)}{U(s)} = \frac{5179}{s^3 + 76,4s^2 + 1392s + 5179} \quad (1)$$

em que $I=5.0 \cdot 10^{-4} \text{kg} \cdot \text{m}^2$ é o momento de inércia da carga conectada ao eixo do servo (o momento de inércia do rotor do servo é muito menor que I).

A carga consiste de dois corpos rígidos iguais interconectados, cada um com momento de inércia de $0.5I$. Na simulação foram consideradas duas falhas. A falha 1 é a mesma falha já utilizadas em trabalhos anteriores, que consiste na ruptura da conexão entre dois corpos e que é modelada por uma redução abrupta de 50% na inércia da carga. A falha 2 simula uma ruptura interna da carga, que faz com que a massas da mesma se concentre em sua periferia, resultando em um incremento de 50% do momento de inércia. Pode ser interpretada como o oposto da Falha 1.

Como base de comparação foi utilizada a análise de resíduos de um observador de Luenberger, uma técnica bastante conhecida de redundância analítica. Os estados estimados foram usados também na detecção de falhas empregando os mapas de Kohonen.

Em contraste com os trabalhos de Souza et. al., (2000) e de Paiva (2003), que utilizavam os mesmo parâmetros do observador de estados e nas simulações de falhas, nesse trabalho são utilizados três conjuntos de parâmetros para o servomecanismo, resultando em uma função de transferência nominal e outras duas funções de transferências que podem ser chamadas de reais. As três funções de transferência, que utilizam parâmetros estimados em medidas realizadas em um mesmo servomecanismo real, são utilizadas para ilustrar os efeitos de erros de modelagem no desempenho dos métodos de detecção de falhas.

O modelo nominal é utilizado em todas as simulações e no projeto de um conjunto de observadores de estados, enquanto que os modelos laboratoriais são utilizados no projeto de outros dois conjuntos de observadores de estado.

A função de transferência do modelo nominal antes da falha pode ser realizada no espaço de estados utilizando a representação do conjunto de equações 2:

$$\begin{aligned} \dot{x}_1 &= 10x_2 \\ \dot{x}_2 &= 100x_3 \\ \dot{x}_3 &= -76,4x_3 - 13,92x_2 - 5,179x_1 + 5,179u \\ y &= x_1 \end{aligned} \quad (2)$$

Quando a Falha 1 ocorre, a expressão de x_3 é modificada para:

$$\dot{x}_3 = -76,4x_3 - 16,48x_2 - 10,36x_1 + 10,36u_2 \quad (3)$$

enquanto as outras expressões em (2) mantêm-se inalteradas.

Do mesmo modo, quando a Falha 2 ocorre, a expressão de x_3 é modificada para:

$$x_3 = -76,4x_3 - 12,64x_2 - 2,59x_1 + 2,59u_2 \quad (4)$$

enquanto as outras expressões em (2) mantêm-se inalteradas.

Como sinal de entrada foi utilizado um trem de pulsos retangulares de amplitude de 1V e período de 2 segundos. Foi utilizada uma frequência de amostragem de 50Hz e as medidas estavam sujeitas a um ruído de 0,02 volts. A Figura 4 ilustra a operação do sistema com a ocorrência da Falha 1 em 3.4 segundos.

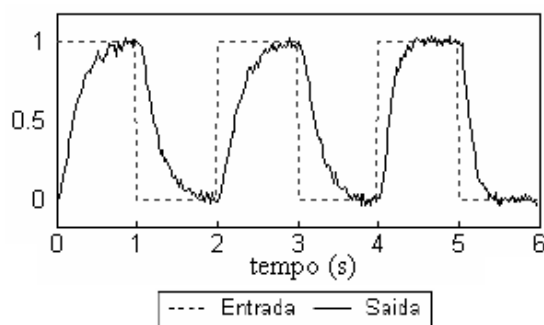


Figura 4. Exemplo de ocorrência da Falha 1 em 3.4 segundos.

4.2 Definição do Conjunto de Treinamento

O servo mecanismo foi simulado e em operação normal (sem ocorrência de falhas) e foram coletados os sinais de entrada, saída e os estados estimados durante 500 ciclos de operação. A Figura 5 ilustra a entrada e saída do sistema em operação normal.




Figura 5. Dados para o treinamento da rede Neural Artificial.

4.3. Resultados Obtidos

Foram simuladas 100 falhas de cada tipo em instantes diferentes para cada um dos três modelos. Tanto a análise de resíduos quanto o método proposto foram utilizados a detecção de falhas do total de 600 falhas simuladas.

Antes da realização do treinamento das redes de Kohonen todos os dados foram normalizados no intervalo de -1 a 1 para que as variáveis com maior variação não tivessem um peso maior na definição.

Foram testados vários tamanhos de mapas bidimensionais, e depois diferentes quantidades de épocas de treinamento, sendo que os melhores resultados foram conseguidos com mapas de 20 x 20 neurônios e o uso de mais de uma época não influenciou no desempenho da rede de Kohonen.

O sucesso dos métodos que utilizam um limiar para a decisão da presença ou a ausência de falhas depende diretamente da correta escolha desse limiar, caso tanto a análise de resíduos quanto do método proposto nesse trabalho. Dessa forma, uma comparação entre os métodos com a utilização de limiares fixos poderia ser tendenciosa. As curvas ROC podem ser usadas para contornar o problema de escolha de limiar para propósitos comparativos.

As curvas ROC são definidas como um gráfico de sensibilidade de um teste como ordenada versus a taxa de falso positivo (FRP – false positive rate) como a abscissa. Elas são uma ferramenta bastante efetiva para analisar o desempenho de testes de diagnóstico (Park et. al., 2004).

Para comparação do desempenho de diferentes métodos de detecção de falhas, as curvas ROC podem ser construídas variando-se o valor de limiar de detecção desde o valor que apresente a maior taxa de correta detecção. Com as taxas de correta detecção e de falso alarme para esses diferentes valores de limiar de detecção constrói-se a curva ROC de cada método de detecção de falhas.

Uma das medidas mais populares associadas às curvas ROC é a área sob a curva (AUC – área under curve) (Vemuri et. al., 2001; Park et. al., 2004; e Faraggi & Reiser, 2002). A AUC é uma medida do desempenho global de um teste de diagnóstico e é interpretada como um valor médio de sensibilidade para todos os valores de especificidade (1-FPR). Quanto mais próximo a AUC estiver da unidade, melhor é o desempenho global do teste. Um teste com uma AUC unitária é um teste perfeitamente acurado.

Para a ocorrência de falsos alarmes, correta detecção e conseqüente construção das curvas ROC, foram considerados um período de operação antes e um período de operação após a simulação de cada falha.

A Figura 6 apresenta as curvas ROC para as duas falhas simuladas e os três modelos utilizados.

Nota-se visivelmente, com exceção de apenas uma situação, um melhor desempenho do método proposto. Os valores de AUCs para a Falha 1 são apresentados na Tabela 1 e para a Falha 2 na Tabela 2.

Tabela 1. AUCs para a Falha 1.

Modelo	Nominal	Modelo 1	Modelo 2
Resíduo	0.84	0.90	0.84
Kohonen	0.82	0.94	0.84

Tabela 2. AUCs para a Falha 2

Modelo	Nominal	Modelo 1	Modelo 2
Resíduo	0.67	0.94	0.79
Kohonen	0.85	0.90	0.82

A média das AUCs para a análise de resíduos foi de 0.77 e para o método proposto 0.86.

Nota-se também uma menor variação da AUC do método proposto tanto com relação às diferentes falhas quanto com relação à utilização de diferentes modelos na obtenção dos estados estimados.

As Tabelas 3 e 4 apresentam o tempo médio de detecção para os dois métodos, tempo decorrido entre a ocorrência da falha e sua correta detecção.

Nota-se que o tempo necessário para a detecção dos dois métodos é bastante similar, o que torna o método proposto preferível do ponto de vista de desempenho na correta detecção de falhas sem a ocorrência de falsos alarmes.

Tabela 3. Tempos Médios de Detecção para a Falha 1.

Modelo	Nominal	Modelo 1	Modelo 2
Resíduos	0.84	0.90	0.84
Kohonen	0.82	0.70	0.82

Tabela 4. Tempos Médios de Detecção para a Falha 2.

Modelo	Nominal	Modelo 1	Modelo 2
Resíduos	0.82	0.72	0.84
Kohonen	0.56	0.56	0.52

5 Conclusão

A utilização de redes Neurais Artificiais empregando os mapas de Kohonen na detecção de falhas se mostra bastante promissora. Com a técnica proposta não há a necessidade de hardware adicional, não há a necessidade de um modelo do sistema e nem a necessidade de conhecimento ou dados sobre a operação do sistema com falhas. O comportamento normal do sistema é aprendido a partir do sistema operando sem falhas e esse comportamento é então verificado através dos pesos neuronais que operam no espaço de dimensões das medidas disponível do sistema. Tal processo de verificação não requer um grande esforço computacional.

Quando comparada à análise de resíduos, técnica de redundância analítica bastante conhecida, através das curvas ROC, o método proposto se mostra superior, com valores de AUC consideravelmente superiores, sem diferenças consideráveis no tempo necessário para a detecção das falhas.

Cabe ressaltar que estes são apenas os resultados iniciais da utilização dos mapas de Kohonen na detecção de falhas e que o método proposto será alvo de mais estudos, podendo ser aprimorado e apresentar resultados ainda melhores no futuro.

Agradecimentos

Os autores agradecem ao ITA (Instituto Tecnológico de Aeronáutica) pelo apoio dado durante o desenvolvimento deste trabalho. O primeiro autor agradece à Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, processo 04/01942-0.

Referências Bibliográficas

- Angeli, C. & Chatzinikilau, A. (2004) On-line fault detection techniques for technical systems: a survey. *International Journal of Computer Science & Applications*, v. 1, n. 1, p. 12-30.
- Aravena, J. L. & Chowdhury, F. N. (2001) Fault detection of flight critical systems. In: *Digital Avionics Systems Conference*, 20., USA.
- Baccarini, L. M. R.; Menezes, B. R. & Caminhas, W. M. (2003) Utilização de redes neurais para diagnóstico de falhas mecânicas em motores de indução trifásicos. In: *Cong. Bras. de Redes Neurais*, 6., v. 1, p. 151-156, São Paulo.
- Basseville, M. & Nikiforov, I.V. (1993) *Detection of abrupt changes: theory and applications*. Prentice-Hall.
- Caminhas, W. M.; Tavares, H. M. F. & Gomide, F. A. C. (2001) Detecção de falhas em sistemas dinâmicos: abordagem baseada em redes neuro-fuzzy com aprendizado. *Cong. Bras. Redes Neurais*, 5., v.1, p.613-618, Rio de Janeiro.
- Chen, J. & Patton, R. J. (1999) *Robust model-based fault diagnosis for dynamic systems*. Norwell, MA: Kluwer Academic Publishers.
- Chien, C. F.; Chen, S. L. & Lin, Y. S. (2002) Using Bayesian network for fault location on distribution feeder. *IEEE Transactions on Power Delivery*, v. 17, n. 13, p. 785-793.
- Duda, R. O.; Hart, P. E. & Stork, D. G. (2001) *Pattern classification*, New York: Wiley.
- Faraggi, D. & Reiser, B. (2002) Estimation of the area under the ROC curve. *Statistics in Medicine*, n. 21, p. 3093-3106.
- Fenton, W. G.; McGinnity, T. M. & Maguire, L. P. (2001) Fault diagnosis of electronic systems using intelligent techniques: a review, *IEEE Trans. on Systems, Man and Cybernetics – Part C*, v. 31, n. 3, p. 269-281.
- Fortuna, L., et. al. (1999) An Innovative Intelligent System for Fault Detection in Tokamak Machines. *Int. Conf. on Accelerators and Large Experimental Physics Control Systems*, Italy.
- Freitas, A. E. S.; Cerqueira, J. J. F. & Ferreira, N. R. (2005) Detecção de falhas em motores de indução por meio de mapas de Kohonen. *Simpósio Brasileiro de Automação Inteligente*, 7., p. 1-8, São Luis.
- Frisk, E. (1993) *Model-based fault diagnosis applied to a SI-engine*. Dissertação de Mestrado, Vehicular Systems, Linköping University.

- Furtado, R. M. F. et al. (2005) Fault identification in rotor system using model based methods, experimental data and artificial neural network. Cong. Int. Eng. Mecânica, p. 1-8. Ouro Preto.
- Gertler, J. J. (1998) Fault detection and diagnosis in engineering systems. New York: Marcel Dekker.
- Hush, D. R. et al. (1997) Neural networks in fault detection: a case study. American Control Conference, Albuquerque.
- Jakubek, S. & Strasser, T. (2002) Neural Networks applied to Automatic Fault Detection, In Proc. of 45th IEEE Midwest Symposium on Circuits and Systems Conference, I-639-I-642, USA.
- Lerner, U., et. al. (2000) Bayesian fault detection and diagnosis in dynamic systems. Proc. of the 17th National Conf. on Artificial Int. :531-537, USA.
- Matsuura, J. P. & Yoneyama, T. (2004a) Learning Bayesian networks for fault detection. In: IEEE Workshop on Machine Learning for Signal Processing, p. 133-142. São Luís.
- Matsuura, J. P. & Yoneyama, T. (2004b) Redes Bayesianas e aprendizagem aplicadas à detecção de falhas em sistemas dinâmicos. Congresso Brasileiro de Automática, p. 1-6, Gramado.
- Mehranbod, N. (2002) A Probabilistic Approach for Sensor Fault Detection and Identification. Tese de Doutorado – Drexel University.
- Mok, H. T. & Chan, C. W. (2005) Online fault diagnosis of nonlinear systems based on neurofuzzy networks. IFAC World Congress, 16., Prague
- Paiva, H.M. (2003) Detecção de Falhas em Sistemas Dinâmicos Empregando Transformadas Wavelet Adaptativas. Dissertação de Mestrado, Eng. Eletrônica e Computação. Instituto Tecnológico de Aeronáutica, São José dos Campos.
- Park, S. H.; Goo, J. M. & Jo, C. H. (2004) Receiver operating characteristic (ROC) curve: practical review for radiologists. Korean Journal of Radiology, n. 5, p. 11-18.
- Patton R. J. & Chen, J. (1992) A robustness study of model-based fault detection for jet engine systems. IEEE Conf. on Control Application, 1., v. 2, p.871-876, USA.
- Patton, R.; Frank, P. & Clark, R. N. (Eds.) (1989) Fault diagnosis in dynamic systems – theory and application. New York: Prentice Hall.
- Patton, R.; Frank, P. & Clark, R. N. (2000) Issues in fault diagnosis for dynamic systems. London: Springer.
- Persin, S., et. al. (2002) Increasing process safety using analytical redundancy. Electrotechnical Review, 69(3-4): 240-246.
- Riascos, L. A. M.; Simões, M. G.; Miyagi, P. E. (2005) Fault identification in fuel cells based on Bayesian network diagnosis. Congresso Int. de Engenharia Mecânica, p. 1-8, Ouro Preto.
- Santoso, N. I. et al. (1999) Nuclear plant fault diagnosis using probabilistic reasoning. IEEE Power Engineering Society Summer Meeting p. 714-719, Canada.
- Sorsa, T.; Koivo, H. N.; Koivisto, H. (1991) Neural networks in process fault diagnosis. IEEE Transactions on Systems, Man and Cybernetics, v. 21, n. 4, p. 815-825.
- Souza, J.A.M.F., Galvão, R.K.H. & Yoneyama, T. (2000) A novel Wavelet-Based Scheme for Fault Detection. Proceedings of UKACC Control, Cambridge, UK.
- Vemuri, A. T.; Polycarpou, M. M. & Ciric, A. R. (2001) Fault diagnosis of differential-algebraic systems. IEEE Transactions on Systems, Man and Cybernetics, Part A, v. 31, n. 2, p. 143-152.
- Venkatasubramanian, V. et al. (2003a) A review of process fault detection and diagnosis part I: quantitative model-based methods. Computers and Chemical Eng., v. 27, p.293-311.
- Venkatasubramanian, V. et al. (2003b) A review of process fault detection and diagnosis part II: quantitative models and search strategies. Computers and Chemical Eng., v. 27, p.313-326.
- Venkatasubramanian, V. et al. (2003c) A review of process fault detection and diagnosis part III: process history based methods. Computers and Chemical Eng., v. 27, p.327-346.
- Wilson, E.; Lages, C.; Mah, R. (2002) Gyro-based maximum-likelihood thruster fault detection and identification. American Control Conf. p.4525-4530, Anchorage.
- Yairi, T.; Kato, Y.; Hori, K. (2001) Fault detection by mining association rules from house-keeping data. Int. Symposium on Artificial Intelligence, Robotics and Automation in Space, Canadá.