



Deteção de Falhas em Sistemas Mecânicos Excitados Estocasticamente através da Análise de Correlações

ALEXANDRE CARLOS EDUARDO & ROBSON PEDERIVA

Departamento de Projeto Mecânico - Faculdade de Engenharia Mecânica – UNICAMP

Caixa postal 6051- CEP: 13.083-970 – Campinas, SP. Brasil.

Email: aceduard@fem.unicamp.br, robson@fem.unicamp.br

Resumo

Este trabalho tem por objetivo abordar o problema de detecção de falhas em um sistema mecânico de dois graus de liberdade submetido a uma excitação estocástica, sendo que este enfoque é feito através da análise das funções de correlação entre os sinais medidos. Utilizou-se um modelo de rede neural Autoregressivo com média móvel (ARMA) para fazer o mapeamento das variações das respectivas funções em relação aos defeitos apresentados, para diferentes condições operacionais do sistema.

Palavras-chave: Deteção de falhas; Sistemas Estocásticos; Análise de Correlações.

1. INTRODUÇÃO

A abordagem sobre o problema de detecção de falhas em sistemas mecânicos tem despertado interesse de vários pesquisadores ao longo dos anos, principalmente no estudo e análise de sistemas onde se possam extrair informações sobre determinados parâmetros relevantes do sistema, como por exemplo, rigidez e amortecimento. Para que se possa extrair tais informações de maneira rápida e precisa, torna-se necessário o conhecimento global do sistema em estudo.

As técnicas convencionais de detecção de falhas baseadas em modelos matemáticos constituem uma forma alternativa para avaliar e monitorar as variáveis e parâmetros do sistema. Para o caso de sistemas mecânicos, um modelo matemático particularmente interessante é aquele que descreve o sistema por equações diferenciais ou séries temporais. No estudo analítico de sistemas dinâmicos a escolha de um modelo matemático adequado está estreitamente ligada ao tipo de análise que se deseja fazer, e também a quais são as características do sistema que são necessárias serem representadas pelo modelo ou quais podem ser desconsideradas (Eykhoff, 1974).

Muitos problemas em Engenharia podem ser formulados envolvendo a resposta dinâmica de um sistema excitado por um processo estocástico. O estudo do comportamento de sistemas excitados estocasticamente foi abordado por alguns autores (Kozin, 1968; Wedig, 1983; Weber & Schiehlen, 1982) trabalharam com a hipótese de que a excitação possa ser considerada de caráter estocástico. Nestes trabalhos apresentaram métodos baseados na matriz de correlações entre as variáveis de estados medidas (deslocamentos e velocidades).

Os métodos estocásticos fundamentados na formulação de modelos matemáticos com base em sinais coletados na entrada e saída de um sistema estrutural (e ou sinais adquiridos na saída do sistema) apresentam a vantagem de serem mais eficazes no processo de identificação e monitoramento de sinais

em presença de ruídos. Uma forma alternativa de MBFD (*model based fault detection*) para sistemas que contém ruídos aleatórios na forma estacionária é utilizar as funções de correlação de sinal. Yaglom (1987, 1962) estudou este problema para sistemas estacionários, onde constatou que as funções de correlação tendem para valores estáveis e constantes. O problema de estimação de parâmetros e detecção de falhas em sistemas dinâmicos estacionários utilizando funções de correlação foi estudada por vários pesquisadores tais como, Tse (1975), El-Sherief (1980), Kubruslky (1983), Pederiva (1992) e Cooper (1994), Chiarello (1998).

Um dos grandes temas de pesquisa nas últimas décadas tem sido à busca de representações matemáticas capazes de reproduzir o comportamento de um sistema linear ou não linear (Narendra e Parthathy, 1990) sendo que uma das principais ferramentas utilizadas atualmente para tal propósito é a Rede Neural Artificial. Pesquisadores como Belli, Conti e Turchetti (1999) estudaram algumas classes de RNA's chamadas de Redes Neurais Estocásticas, onde as mesmas são capazes de aproximar mapeamentos de sinais estocásticos. Utilizaram as informações do sinal de saída do processo, formulando matematicamente uma relação entre os parâmetros do processo e os pesos sinápticos da rede neural estocástica, comparando a função de covariância modelada e da rede. A classe de RNA's estocásticas pode ser considerada uma generalização da usual definição das RNA's. Este estudo apresentou uma abordagem bastante interessante em se tratando da abordagem matemática e física de problemas reais na prática.

A importância dessas análises dá-se ao fato que as mesmas podem ser estendidas para uma formulação matemática mais detalhada no processo de monitoramento e detecção de falhas em sistemas mecânicos, submetido a sinais estocásticos que variam com o tempo.

O enfoque deste trabalho consiste em obter e analisar as funções de correlação dos sinais medidos de um sistema mecânico de dois graus de liberdade submetido a uma excitação estocástica, onde qualquer variação nos parâmetros do mesmo possam ser observadas. Esta abordagem procura associar técnicas analíticas, utilizadas para sistemas dinâmicos, utilizando RNA's (Redes Neurais Artificiais) objetivando a sua aplicação a casos reais, onde ruídos e incertezas estão presentes. A combinação ou complementação destas duas ferramentas representa procedimentos poderosos para processar e integrar informações de natureza quantitativa e qualitativa.

2. DESCRIÇÃO DO MODELO DO SISTEMA EM ESTUDO

Seja um sistema dinâmico abaixo,

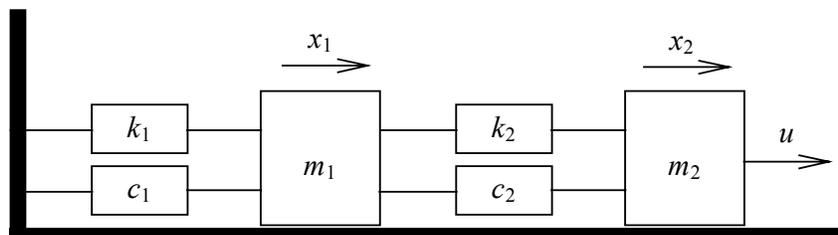


Figura 2.1- Sistema dinâmico de dois graus de liberdade

descrito pela equação diferencial:

$$M\ddot{d}(t) + P\dot{d}(t) + Qd(t) = Su(t) \quad 2.1$$

onde:

M é uma matriz quadrada de ordem p denominada matriz de massa; P é uma matriz (p,p) correspondente às forças proporcionais às velocidades; Q é uma matriz (p,p) correspondente às forças proporcionais aos deslocamentos; S é uma matriz (p,f) de entradas; $u(t)$ é um vetor f -dimensional das excitações ou entradas; $\ddot{d}(t), \dot{d}(t), d(t)$ são vetores p dimensionais correspondentes aos deslocamentos, velocidades e acelerações respectivamente.

A equação 2.1 em tempo-contínuo pode ser escrita como

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) \\ y(t) &= Cx(t) \end{aligned} \quad 2.2$$

com

$$A = \begin{bmatrix} 0 & I \\ -M^{-1}Q & -M^{-1}P \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ -M^{-1}S \end{bmatrix}, \quad C = \begin{bmatrix} I & : & 0 \end{bmatrix} \quad 2.3$$

$$\ddot{d}(t) = \begin{Bmatrix} \ddot{x}_1(t) \\ \ddot{x}_2(t) \end{Bmatrix}, \quad \dot{d}(t) = \begin{Bmatrix} \dot{x}_1(t) \\ \dot{x}_2(t) \end{Bmatrix}, \quad d(t) = \begin{Bmatrix} x_1(t) \\ x_2(t) \end{Bmatrix}$$

A Tabela 2.1 mostra os valores dos parâmetros físicos do sistema:

Parâmetros	Símbolo	Unidade
massa 1 = 10	m_1	kg
massa 2 = 20	m_2	kg
rigidez 1 = 2000	k_1	N/m
rigidez 2 = 10	k_2	N/m
amortecimento 1 = 2000	c_1	N.m/s
amortecimento 2 = 10	c_2	N.m/s

Tabela 2.1- Valores dos parâmetros do sistema

O vetor x é dito vetor de estados e contém os deslocamentos e velocidades do sistema; $y(t)$ representa as variáveis de estado que podem ser diretamente medidas. As matrizes I e O representam respectivamente a matriz identidade e a matriz nula. Assume-se que a excitação $u(t)$ seja um processo tipo ruído branco.

Reescrevendo a equação 2.2 na forma discretizada no tempo tem-se:

$$\begin{aligned}x(t_k + 1) &= Fx(t_k) + Gu(t_k) \\y(t_k + 1) &= Cx(t_k)\end{aligned}\tag{2.4}$$

onde:

$$t_k = t(k\Delta t), \quad k = 0, 1, \dots, n\tag{2.5}$$

$$F = e^{A\Delta t}\tag{2.6}$$

sendo Δt o tempo de discretização do sinal medido. No caso em estudo, em que a matriz A do sistema é regular (Kozin, 1968),

$$G = \int_0^{\Delta t} e^{A(\Delta t-s)} B ds = (F - I)A^{-1}B,\tag{2.7}$$

Considera-se que o sistema na forma (2.4) seja invariante com entradas estacionárias. Nesta condição as funções de correlação assumem valores constantes no tempo e dependem somente da defasagem temporal τ (Yaglom, 1987, 1962).

3. REPRESENTAÇÃO MATEMÁTICA DA REDE NEURAL ESTOCÁSTICA

A partir da equação (2.4), define-se as funções de autocorrelação entre os sinais medidos,

$$\begin{aligned}R_{uu}(t_k, \tau) &= \frac{1}{N} \sum_{k=0}^N u(t_k) * u^T(t_k + \tau) \\R_{y_1 y_1}(t_k, \tau) &= \frac{1}{N} \sum_{k=0}^N y_1(t_k) * y_1^T(t_k + \tau)\end{aligned}\tag{3.1}$$

onde:

R_{uu} é a função de autocorrelação do sinal de excitação estocástico $u(t)$; $R_{y_1 y_1}$ é a função de autocorrelação do vetor de medidas y_1 .

Sendo o sistema observável a partir da variável y_1 , pode-se descrever o comportamento da mesma usando o modelo ARMA (Autoregressivo de média móvel),

$$y_1(t_k) = \delta_o + a_1 y_1(t_k - 1) + \dots + a_n y_1(t_k - n) + \dots + b_1 u(t_k - 1) + \dots + b_n u(t_k - n)\tag{3.2}$$

Neste caso, a equação 3.1 pode ser escrita na forma,

onde:

a_1, \dots, a_n , e b_1, \dots, b_n são os parâmetros do modelo ARMA (Autoregressivo de médias móveis); n é a ordem do modelo.

Segundo Haykin (1994) uma rede neural usando modelo ARMA pode ser composta por regressores das funções de autocorrelação dos sinais medidos com valores passados (camada de entrada), uma camada intermediária e uma camada de saída:

$$R_{y1y1} = f \left(\sum_{n=1}^N w_n R_{y1y1}(t_k - n) + \sum_{n=1}^J \rho_n R_{uu}(t_k - n) \right) \quad 3.3$$

onde: w_i , ρ_j representam os pesos da rede ; $n_{(1,...,4)}$: representa a ordem do modelo; $f(.)$ é a função ativação tangente hiperbólica

Para o caso em estudo (sistema dinâmico submetido a uma excitação estocástica) a estrutura da rede neural estocástica recursiva utilizada foi:

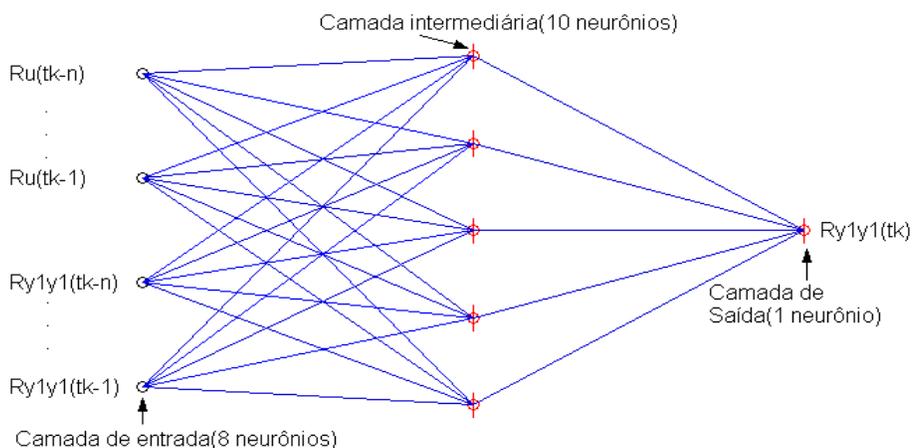


Figura 3.1- Estrutura da rede neural utilizada

Quanto à definição do algoritmo de treinamento proposto para a rede, realizou-se testes com retropropagação do erro Rumelhart (1995), Demuth (1994), Haykin (1994) implementado com momentum e com o método de otimização proposto por Levenberg-Marquardt (Grace, 1992).

4. METODOLOGIA

Neste trabalho, procurou-se aplicar a metodologia utilizada por Turchetti (1999) na modelagem de sistemas estocásticos, ressaltando, porém, a aplicabilidade desta metodologia no problema de detecção

de falhas em um sistema mecânico submetido a uma excitação estocástica, onde através da função de autocorrelação dos sinais medidos, pode-se analisar prováveis falhas do sistema.

Para obtenção das falhas no sistema mecânico foram alterados os valores dos parâmetros tais como rigidez, amortecimento e acrescentou-se ruído branco na entrada do sistema. Com o objetivo de verificar a influência das alterações dos respectivos parâmetros na função de autocorrelação dos sinais medidos, adotou-se um percentual subjetivo de falha, conforme mostrado na Tabela 4.1:

CONDIÇÃO	DESCRIÇÃO DA FALHA
1	Redução de 20 % em c_1
2	Redução de 20 % em k_1
3	Redução de 20 % em c_2
4	Redução de 20 % em k_2

Tabela 4.1- Condições dos parâmetros do sistema com falha

Para cada condição operacional do sistema, foram alterados os valores individuais dos parâmetros em estudo, e mantido os outros valores constantes.

Abaixo é descrita a metodologia empregada no enfoque da detecção de falhas em sistema mecânico submetido a uma excitação estocástica:

- Obtenção das respostas do sistema com as respectivas funções de autocorrelação em cada condição operacional (sem falha).
- Emprego da rede neural recursiva para fazer o mapeamento da função de autocorrelação dos sinais medidos do sistema sem falha;
- Variações nos parâmetros do sistema (redução nos valores de rigidez e amortecimento);
- Emprego da rede neural recursiva para fazer o mapeamento da função de autocorrelação dos sinais medidos do sistema com falha;

5. RESULTADOS E DISCUSSÕES

Passa-se, agora apresentar os resultados obtidos através das simulações realizadas do sistema, com presença de falhas nos parâmetros em situações diversas. O que se deseja é caracterizar o comportamento da função de autocorrelação dos sinais medidos do sistema, mediante condições de falhas e procurar através da rede neural recursiva fazer o mapeamento da respectiva função de autocorrelação.

Observou-se que os respectivos pesos sinápticos da rede tendem para valores iguais aos dos parâmetros do modelo ARMA (Autoregressivo com média móvel), sendo que a diferença entre ambos chega a valores na ordem de 10^{-4} .

A utilização do algoritmo de Levenberg-Marquardt mostrou-se mais eficiente no desempenho da rede recursiva, chegando a um erro de treinamento 10^{-3} , num tempo de execução muito menor que o backpropagation, por exemplo. Foram testadas 4 arquiteturas para fazer o treinamento da rede, com variações no número de neurônios da camada intermediária. Observa-se pela Tabela 5.1 que a

arquitetura que apresentou uma melhor desempenho foi a 8,10,1 (8 neurônios na camada de entrada, 10 na camada intermediária, e um na saída). Levou-se em consideração principalmente ao número de iterações realizadas.

NO	ARQUITETURA DA REDE	ITERAÇÕES	PERFORMANCE (%)
1	8,6,1	355	33.0
2	8,12,1	250	86.0
3	8,10,1	190	98.75
4	8,18,1	215	73.5

Tabela 5.1- Arquiteturas e Performances da rede

A Figura 5.2 apresenta o comportamento das funções de autocorrelação dos sinais medidos sem falha do sistema e a obtida pela rede neural, seguindo a o critério da tabela 4.1.

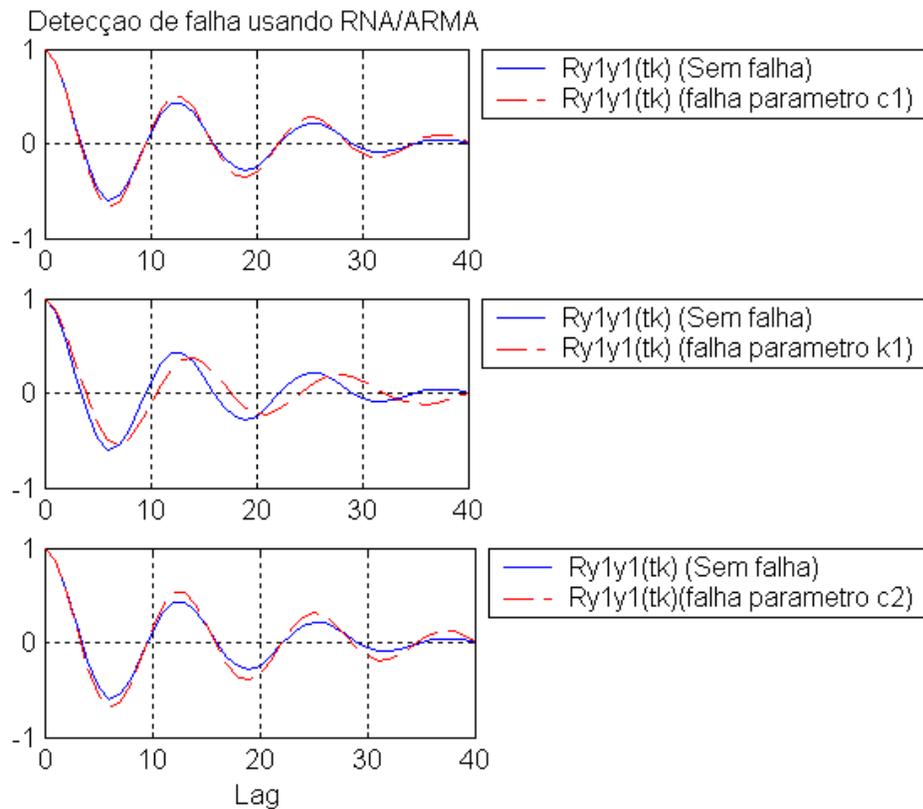


Figura 5.2 – Comparação da Autocorrelação obtida pela Rede Neural usando modelo ARMA (Sistema sem falha e Sistema com falha)

Observa-se pelo comportamento das funções de autocorrelação nas condições 1 (redução de 20 % nos valores de c_1) e condição 3 (redução de 20 % de c_2), uma ligeira alteração em relação à amplitude do sinal, sendo que na condição 2 (redução de 20 % nos valores de k_1) uma alteração em relação à faixa do tempo. Particularmente para este caso, pode-se dizer que os parâmetros c_1 e c_2 tem influência direta no comportamento da função de autocorrelação entre os sinais medidos. Para se escolher o padrão de entrada adequado foram realizados vários testes, pois, este é um processo fundamental dentro desta metodologia. Para a entrada de dados foram apresentadas duas curvas da função de autocorrelação entre os sinais medidos, a primeira curva (sem defeito) tendo como saída 0 e a segunda curva (com defeito) tendo como saída 1.

A Figura 5.3 mostra o desempenho das arquiteturas das Redes Neurais utilizadas, onde se analisam as respectivas saídas e as condições de falhas do sistema.

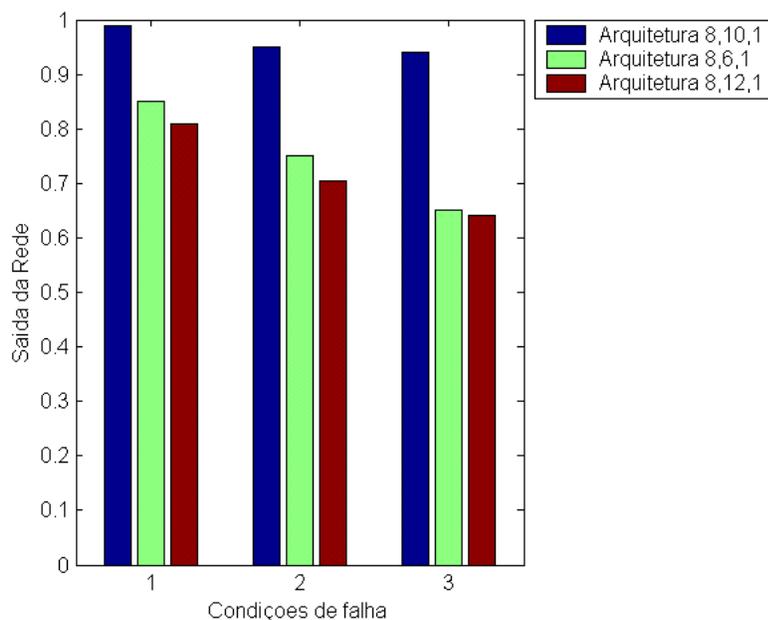


Figura 5.3- Desempenho das Arquiteturas da Rede Neural analisando as respectivas saídas e as condições de falhas do sistema

O desempenho da arquitetura 8,10,1 (8 neurônios na camada de entrada, 10 na camada intermediária e 1 na saída) em relação às outras arquiteturas, é considerado satisfatório nas três condições de falhas impostas ao sistema. Apresentando valores da ordem de 0.99, 0.95 e 0.94 na saída da rede, sendo que para condição de falha o valor máximo é 1.0. O desempenho da rede é definido como sendo a condição de falha do sistema atingindo o valor máximo 1.0.:

6. CONCLUSÕES

Os resultados das simulações mostram claramente a capacidade de uma rede neural recursiva, de modelar o comportamento dos sistemas mecânicos, mostrando que a aplicação desse tipo de rede neural é capaz de aproximar o comportamento de uma função de caráter aleatório. O grau de precisão desta aproximação depende do algoritmo de aprendizado e do número de neurônios utilizados.

Os pesos sinápticos da rede convergem a valores praticamente iguais aos parâmetros do modelo ARMA. Este fato abre novas perspectivas em si tratando de modelagem de sistemas dinâmicos onde não se conhece a priori o(s) parâmetro(s) do sistema, podendo para isso relacionar tais parâmetros com os pesos sinápticos da rede neural artificial.

As falhas geradas no modelo modificaram as funções de autocorrelação dos sinais medidos, sendo que para este sistema específico, os valores dos amortecimentos c_1 e c_2 , tem uma influência mais significativa no mapeamento da função de correlação.

7. REFERÊNCIAS

- Basseville, M., Benveniste, A., Moustakides, G., Rougee, A. (1988). Detection and diagnosis of changes in eigenstructure of nonstationary multivariable systems. *Automatica*, vol. 23, n.4, p.479-489.
- Belli, M. R, Conti, M., Crippa, P. and Turchetti, C. (1999). Artificial neural networks as approximators of stochastic processes. *Neural Network* .pp. 647-658.
- Chauvin, Yves; Rumelhart, David E. (1995). *Backpropagation Theory: Architectures and Applications*. Laurence Erlbaum Associates, Inc.
- Chiarello, A.G. (1998) Detecção e Localização de Falhas em Sistemas Mecânicos Estacionários Através de funções de Correlação. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Mecânica, Universidade Estadual de Campinas-UNICAMP, SP.
- Cooper, J.E., Desforges, M., Wright, J. R. Extraction of modal parameters from unknown coloured random input. In ISMA 19 - Tools for Noise and Vibration Analysis. *Proceedings*, p.1123-1128, 1994(a).
- Demuth, Howard; Beale, Mark (1994). *Neural Network Toolbox*. Math Works Inc.
- El-Sherief, H. (1980). Multivariable system structure and parameter identification using the correlation method. *International Federation of Automatic Control*, p. 541-544.
- Eykhoff, P. (1974). *System Identification – Parameter and State Estimation*. John Willey & Sons.

- Haykin, Simon (1994). Neural Networks. As Comprehensive foudation. Macmillian College Publishing Company, Inc,.
- Kozin, F.; Kozin, C.H. (1968). A Moment Technique for System Parameter Identification, Shock and Vibr. Bull.8.
- Narendra , K. S.; Parthathy, K., (1990). Identification an control of dynamical systems using neural networks, *IEEE Transactions on neural networks*, vol.1, n.1, p.4-27.
- Pederiva, R., (1992). Identificação Paramétrica de Sistemas Mecânicos Excitados Estocasticamente. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Mecânica, Universidade Estadual de Campinas-UNICAMP, SP.
- Yaglom, A M. (1987).Correlation Theory of Stationary and Related Random Functions I, Springer-Verlag.

Fault detection in mechanical systems excited by stochastic forces through correlation analysis

ALEXANDRE CARLOS EDUARDO & ROBSON PEDERIVA

Departamento de Projeto Mecânico- Faculdade de Engenharia Mecânica – UNICAMP

Caixa postal 6051- CEP: 13.083-970 – Campinas, SP. Brasil.

Email: aceduard@fem.unicamp.br, robson@fem.unicamp.br

Abstract:

This work deals with the problem of fault detection of a two degrees of freedom dynamical system excited by stochastic forces through correlation functions the measured signals. A autoregressive moving average (ARMA) model of neural network was used to make the mapping of the variations of the respective functions in relation to presented fault, for different operational conditions of the system.

Keywords:

Fault detection, Stochastic systems, Correlation analysis.