

TÉCNICA HÍBRIDA PARA DETECÇÃO E DIAGNÓSTICO DE DEFEITOS EM MÁQUINAS ROTATIVAS UTILIZANDO MODELOS MATEMÁTICOS

HYBRID TECHNIQUE FOR FAULT DETECTION AND DIAGNOSIS IN ROTATING MACHINES UTILIZING MATHEMATICAL MODELS

Alexandre Carlos Eduardo

Universidade Federal de Minas Gerais
Escola de Engenharia – Departamento de Engenharia Mecânica
Av. Antônio Carlos, 6627 - Pampulha
CEP: 31270-901 Belo Horizonte, MG Brasil
E-mail: aceduard@demec.ufmg.br

RESUMO

Este trabalho propõe uma técnica híbrida para detecção e diagnóstico de defeitos em máquinas rotativas utilizando modelos matemáticos. O método é baseado na combinação da Análise de Correlações baseada na Matriz de Ljapunov e Redes Neurais Artificiais (RNA's). Este procedimento de diagnóstico de defeitos utiliza somente as variáveis de estado medidas, não sendo necessário a medida direta da excitação estocástica. Usando as propriedades de correlações das variáveis de saída, é possível derivar relações específicas envolvendo os parâmetros físicos do sistema e as matrizes de correlações das variáveis medidas. O defeito no sistema rotativo é detectado monitorando a variação dos parâmetros físicos, através da comparação das funções de correlações teóricas e estimadas. Redes Neurais Artificiais são usadas como ferramentas para mapear tais correlações. São discutidas as aproximações numéricas para um sistema rotativo modelado com seis graus de liberdade. Os bons resultados mostram a viabilidade de estudos adicionais nesta área.

Palavras-chave: Diagnóstico de defeitos, Análise de correlações, Equação de Ljapunov, Redes Neurais Artificiais.

ABSTRACT

A hybrid techniques for fault detection and diagnosis in rotating machines utilizing mathematical model, is proposed in this paper. The methodology is derived using a combination of correlation analysis based on the Ljapunov Matrix and Artificial Neural Network (ANN). This procedure of parameter fault diagnosis uses only measured state variables. The direct measurement of the stochastic excitation is not necessary. Coloured noise stochastic excitation is modeled by a dynamical system excited by white noise. Using the properties of correlation of the output variables, it is possible to derive specific relations involving the physical parameters of the system and the correlation matrices of the measured variables. Faults in the rotor can be detected by monitoring the variation of the physical parameters through a comparison of theoretical and estimated correlation functions. Artificial Neural Network is used as a tool to map such correlations. The numerical approaches for rotor systems modeled with six degrees of freedom are discussed with respect to this methodology. The good results show the viability of further studies in this area.

Keywords: Fault Detection, Rotating Machines, Mathematical Models.

1 – INTRODUÇÃO

Nos últimos anos têm-se utilizado as redes neurais artificiais para representar o conhecimento e reconhecer padrões de defeitos em sistemas dinâmicos, Chena e Lee, [1].

As metodologias convencionais de diagnóstico de defeitos nem sempre resolvem particularidades inerentes à natureza do problema. Tem-se, então, de se fazer mudanças e/ou complementações em suas formulações, Eduardo [2]. Pode-se citar como casos típicos de tais particularidades: identificação de forças de excitação aplicadas ao sistema; impossibilidade de medição de determinadas forças aleatórias, como por exemplo, o

contato entre fluido/estrutura em uma turbina; excitação transmitida de uma máquina para outra. É nesta temática que este trabalho é desenvolvido.

Arquiteturas de redes neurais de vários tipos foram utilizadas visando à detecção de defeitos: Belli et all [3], exploraram as capacidades e habilidades das Redes Neurais em aproximar processos estocásticos, mapeamento de dados de entrada e saída determinísticos.

Neste trabalho é apresentada uma metodologia de diagnóstico de defeitos em um sistema mecânico rotativo com inclusão de forças de desbalanceamentos desconhecidas, onde ruídos e incertezas estão presentes.

Através da equação de espaço de estado e da definição da função de correlação para sistemas estacionários,

obteve-se a Equação Matricial de Ljapunov que contempla os parâmetros físicos do sistema com as funções de correlação entre os sinais medidos.

Redes Neurais são utilizadas para mapear variações nas variáveis de estado medidas. São determinados os Desvios Quadráticos Médios das diferenças observadas entre as correlações de cada arquitetura. Para implementação computacional foram usados os recursos do software Matlab® e Simulink®. A utilização desta metodologia para monitoramento e diagnóstico de defeitos em máquinas rotativas é uma abordagem relevante e original.

2 – MODELAGEM TEÓRICA

É feita uma modelagem matemática de um sistema mecânico rotativo obtendo-se a resposta do sistema na forma da equação de espaço de estado discretizada no tempo. Assume-se que a excitação seja um processo do tipo ruído de banda estreita como excitação. Estas excitações são obtidas a partir de um filtro em um sinal ruído branco.

2.1 Modelo Matemático de um Sistema Mecânico

A equação diferencial de movimento para um sistema mecânico pode ser escrita na forma matricial:

$$M\ddot{\xi}(t) + P\dot{\xi}(t) + Q\xi(t) = Su(t) + Hn(t) \quad (1)$$

onde: M é uma matriz quadrada denominada matriz de massa, onde se encontram os parâmetros inerciais do sistema; P é uma matriz correspondente às forças proporcionais às velocidades denominada matriz de amortecimento, onde estão os parâmetros dissipativos; Q é uma matriz correspondente às forças proporcionais aos deslocamentos denominada matriz de rigidez, e concentra os parâmetros de restauração do movimento; S é a matriz de entradas; A matriz H corresponde à matriz de entrada e $u(t)$ é um vetor das excitações ou entradas; o vetor $n(t)$ é um sinal harmônico com frequência Ω ; $\ddot{\xi}(t)$, $\dot{\xi}(t)$, $\xi(t)$ são vetores correspondentes as acelerações, velocidades e deslocamentos.

2.2 Representação da Equação no Espaço de Estados

A Equação (1) pode ser reescrita como,

$$\dot{x}(t) = Ax(t) + Bu(t) + En(t) \quad (2)$$

Considere o vetor de estado $x(t)$,

$$x^T(t) = \{\xi(t) \quad \dot{\xi}(t)\} \quad (3)$$

Com,

$$A = \begin{bmatrix} 0 & I \\ -M^{-1}Q & -M^{-1}P \end{bmatrix} = \begin{bmatrix} 0 & I \\ A_1 & A_2 \end{bmatrix} \quad (4)$$

$$B = \begin{bmatrix} 0 \\ M^{-1}S \end{bmatrix} = \begin{bmatrix} 0 \\ B_1 \end{bmatrix}; E = \begin{bmatrix} 0 \\ M^{-1}H \end{bmatrix} = \begin{bmatrix} 0 \\ E_1 \end{bmatrix} \quad (5)$$

$$n(t) = \begin{bmatrix} \cos(\Omega t) \\ \sin(\Omega t) \end{bmatrix} \quad (6)$$

2.3 Resposta de Sistemas Excitados por Ruído de banda estreita

Uma alternativa para se modelar o sistema quando o mesmo for excitado por um ruído não branco, é utilizar um sistema auxiliar denominado filtro. Filtros são designados para eliminar componentes de frequências indesejadas de um sinal. Estas componentes indesejadas são geralmente conhecidas como ruídos (Miner e Comer, [4]). A utilização de um sistema dinâmico auxiliar foi explorada por Pederiva [5] na identificação de parâmetros em sistemas mecânicos com excitação não medida. Neste trabalho, o sistema original será excitado por um ruído não branco obtido através da filtragem de um sinal do tipo ruído branco.

A Figura 1 ilustra a representação esquemática de um sistema mecânico excitado por ruído sistema de banda estreita).




Figura 1. Representação esquemática de um sistema mecânico excitado por ruído colorido.

Na Equação (2), se $u(t)$ não é um ruído branco, este pode ser modelado como a saída de um sistema dinâmico similar denominado filtro (Figura 1).

Considerando o sistema dinâmico

$$\dot{z}(t) = Rz(t) + S^*w(t) \quad (7)$$

$z(t)$ é o vetor de estado, R é uma matriz regular, e S^* a matriz de entrada.

$$R = \begin{bmatrix} 0 & 1 \\ r_1 & r_2 \end{bmatrix}; \quad S^* = \begin{bmatrix} s_1 \\ s_2 \end{bmatrix} \quad (8)$$

A entrada $u(t)$ do sistema dinâmico (Equação 2) é um processo colorido,

$$u(t) = H_u z(t) \quad (9)$$

Considerando-se que o modelo de estado do sistema mecânico é dado pela Equação (2) pode-se montar o modelo de estado expandido aumentando-se o vetor de

estado original $x(t)$ e o vetor de estados do sistema filtro, $w(t)$. Utilizando as Equações (2), (7), (8) e (9), obtém-se o modelo de estado expandido assume a seguinte forma,

$$\dot{x}^*(t) = A^* x(t) + B^* w(t) + E^* n(t) \tag{10}$$

$$y^*(t) = Cx(t) \tag{11}$$

com as seguintes definições:

$$x^*(t) = \begin{Bmatrix} x(t) \\ \dots \\ z(t) \end{Bmatrix} \tag{12}$$

$$E^* = \begin{Bmatrix} E \\ \dots \\ 0 \end{Bmatrix} \tag{13}$$

C é um vetor de saída ou resposta.

As novas sub-matrizes do sistema A^* e B^* têm a seguinte estrutura,

$$A^* = \begin{bmatrix} A & \vdots & B \\ \dots & \vdots & \dots \\ 0 & \vdots & R \end{bmatrix} \quad \text{e} \quad B^* = \begin{Bmatrix} 0 \\ \dots \\ s_1 \\ s_2 \end{Bmatrix} \tag{14}$$

Sendo $w(t)$ não correlato com $n(t)$, ou seja,

$$R_{wn}(\tau_i) = 0 \tag{15}$$

A resposta do sistema dinâmico pode ser composta de uma superposição da resposta à excitação estocástica $x_w(t)$ e da resposta à excitação harmônica $x_n(t)$.

$$x^*(t) = x_w(t) + x_n(t) = x_w(t) + q_1 \cos \Omega t + q_2 \sin \Omega t \tag{16}$$

onde q_1 e q_2 contém os vetores de amplitudes de vibração do sistema.

A matriz de correlação $R_{x^*x^*}(\tau_i)$ pode ser escrita como:

$$R_{x^*x^*}(\tau_i) = \mathcal{E} \{ x^*(t) x^{*T}(t + \tau_i) \} \tag{17}$$

Substituindo a solução da equação espaço de estado (10) e (16) na Equação (17) assumindo a condição de estacionaridade (Melsa e Sage [6]), tem a seguinte relação,

$$A^* R_{x^*x^*}(\tau_i) + R_{x^*x^*}(\tau_i) A^{*T} + E^* R_{nx^*}(\tau_i) + R_{x^*n}(\tau_i) E^{*T} = -B^* \psi_{ww} B^{*T} e^{A^{*T} \tau_i} \tag{18}$$

onde ψ_{ww} é a matriz intensidade do processo de excitação $w(t)$.

Expandindo a Eq. (18),

$$\begin{bmatrix} A & B \\ 0 & R \end{bmatrix} \begin{bmatrix} R_{x^*x^*} & R_{x^*z} \\ R_{zx^*} & R_{zz} \end{bmatrix} + \begin{bmatrix} R_{x^*x^*} & R_{x^*z} \\ R_{zx^*} & R_{zz} \end{bmatrix} \begin{bmatrix} A^T & 0 \\ B^T & R^T \end{bmatrix} + \begin{bmatrix} E \\ 0 \end{bmatrix} \begin{bmatrix} R_{nx^*} & R_{nz} \end{bmatrix} + \begin{bmatrix} R_{x^*n} \\ R_{zn} \end{bmatrix} \begin{bmatrix} E^T & 0 \end{bmatrix} = - \begin{bmatrix} 0 & 0 \\ 0 & B_1 \psi_{ww} B_1^T \end{bmatrix} e^{A^T \tau_i} \tag{19}$$

Expandindo (19),

$$\begin{bmatrix} 0 & I & 0 \\ A_1 & A_2 & B \\ 0 & 0 & R \end{bmatrix} \begin{bmatrix} R_{\xi\xi} & R_{\xi\dot{\xi}} & R_{z\xi} \\ R_{\dot{\xi}\xi} & R_{\dot{\xi}\dot{\xi}} & R_{\dot{\xi}z} \\ R_{\xi z} & R_{z\xi} & R_{zz} \end{bmatrix} + \begin{bmatrix} R_{\xi\xi} & R_{\xi\dot{\xi}} & R_{z\xi} \\ R_{\dot{\xi}\xi} & R_{\dot{\xi}\dot{\xi}} & R_{\dot{\xi}z} \\ R_{\xi z} & R_{z\xi} & R_{zz} \end{bmatrix} \begin{bmatrix} 0 & A_1^T & 0 \\ I & A_2^T & 0 \\ 0 & B^T & R^T \end{bmatrix} + \begin{bmatrix} 0 \\ E_1 \\ 0 \end{bmatrix} \begin{bmatrix} R_{n\xi} & R_{n\dot{\xi}} & R_{nz} \end{bmatrix} + \begin{bmatrix} R_{n\xi} \\ R_{n\dot{\xi}} \\ R_{nz} \end{bmatrix} \begin{bmatrix} 0 & E_1^T & 0 \end{bmatrix} = - \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & B_1 \psi_{ww} B_1^T \end{bmatrix} e^{A^T \tau_i} \tag{20}$$

Fazendo a multiplicação das sub-matrizes, obtém-se a seguinte equação:

$$R_{\xi\xi}(\tau_i) + R_{\xi\xi}(\tau_i) A_1^T + R_{\xi\dot{\xi}}(\tau_i) A_2^T + R_{z\xi}(\tau_i) B^T + R_{n\xi} E_1^T = 0 \tag{21}$$

A Equação (21) contém relações entre as funções de correlações entre os sinais medidos (deslocamentos e velocidades) e os parâmetros físicos da equação diferencial (Eq. 2). Esta equação contém também correlação entre as forças de desbalanceamento e a saída, podendo ser desenvolvida e simplificada.

3 – DESENVOLVIMENTO DA METODOLOGIA PARA DIAGNÓSTICO DE DEFEITOS EM SISTEMAS MECÂNICOS ROTATIVOS

A utilização de um sistema híbrido no diagnóstico de defeitos em sistemas rotativos, quando adequadamente empregado, é um importante fator para a obtenção de sucesso nas aplicações, em particular no que diz respeito ao tempo gasto no projeto e na consistência dos resultados.

3.1 Fluxograma geral do processo de diagnóstico de defeitos

Na Figura 2 tem-se um fluxograma geral do processo de diagnóstico de defeitos implementado no Matlab & Simulink, possibilitando assim uma maior versatilidade na manipulação para futuras modificações.

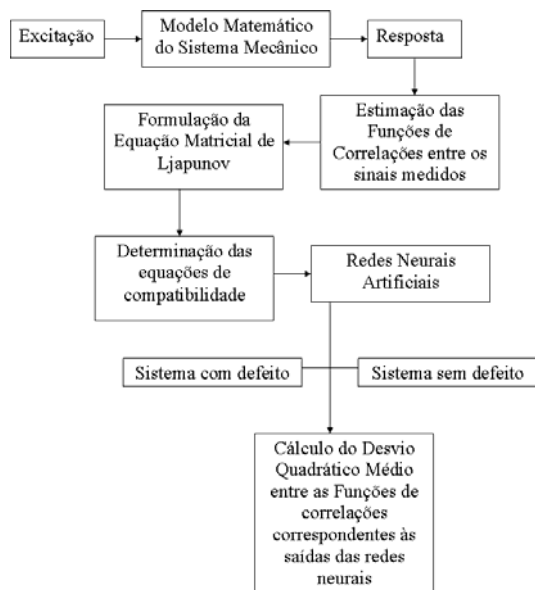


Figura 2. Fluxograma geral do processo de diagnóstico de defeitos.

A idéia básica do sistema de diagnóstico de defeitos em sistemas mecânicos rotativos proposto neste trabalho é fazer a conexão entre a formulação analítica da equação matricial de Ljapunov e redes neurais. Esta passagem requer um certo grau de conhecimento em relação ao comportamento dos pesos sinápticos da rede neural, correspondendo aos parâmetros físicos do sistema e pesos aleatórios (Belli et al, [3]).

A Figura 3 ilustra a estrutura da rede neural que será usada para o monitoramento e diagnóstico de defeitos no sistema mecânico rotativo.




Figura 3. Estrutura da RNA proposta para Diagnóstico de Defeitos em Sistemas Mecânicos Rotativos.

A arquitetura da rede é muito importante para as capacidades de convergência e generalização das RNA's. A escolha de uma arquitetura adequada, nem tão grande e nem tão pequena, é a principal responsável pelo sucesso de uma aplicação. Para se obter uma boa habilidade de generalização, deve-se projetar a rede colocando dentro dela o máximo conhecimento possível sobre o problema (por exemplo, a topologia do espaço de entradas) e limitar o número de conexões adequadamente (Haykin, [7]).

4 – SIMULAÇÕES COMPUTACIONAIS

Neste item apresenta-se a aplicabilidade do Método de Diagnóstico de Defeitos desenvolvido nos itens 2 e 3.

Em qualquer exemplo estudado, considera-se que os parâmetros sejam constantes e qualquer alteração no valor numérico de um parâmetro físico represente um defeito no sistema.

4.1 Aplicação

Neste caso será avaliado o método de diagnóstico de defeitos definidos anteriormente. Será utilizado o modelo matemático de um sistema mecânico rotativo com 6 graus de liberdade estudado por Pederiva [5]. A Figura 4 apresenta o sistema rotativo analisado.




Figura 4. Sistema rotativo com 6 graus de liberdade.

O modelo constitui-se de um rotor acoplado a um motor por um eixo flexível. Entre o motor e o rotor existe um mancal de massa m_1 suspenso elasticamente. Os graus de liberdade se traduzem nas translações y_1 e z_1 do mancal, nas translações y_2 e z_2 do rotor e nas rotações ϕ_2 e ψ_2 do rotor. O motor de acionamento é considerado engastado. O rotor de massa m_2 tem momento de inércia transversal I_2 e momento polar I_{2P} . Este modelo possui diversos parâmetros conhecidos, o que poderá ajudar na formulação da metodologia empregada para o monitoramento de defeitos do sistema. Considera-se também que os efeitos dos momentos de inércia da estrutura do mancal sejam desprezíveis.

A Equação geral de movimento que descreve o comportamento dinâmico do sistema na forma geral (1) tem o seguinte vetor de deslocamentos:

$$\xi^T = \{y_1 \quad y_2 \quad \psi_2 \quad z_1 \quad z_2 \quad \phi_2\} \quad (22)$$

onde as variáveis y_1 e z_1 representam os deslocamentos no mancal nas direções Y_1 e Z_1 , respectivamente; as variáveis y_2 e z_2 representam os deslocamentos do rotor nas direções Y_1 e Z_1 , respectivamente. As variáveis ϕ_2 e ψ_2 representam rotações do rotor em torno dos eixos Y_1 e Z_1 , respectivamente. As matrizes deste sistema têm as seguintes estruturas internas:

$$M = \text{diag}\{m_1 \quad m_2 \quad I_2 \quad m_1 \quad m_2 \quad I_2\} \quad (23)$$

$$P = \begin{bmatrix} C_1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & \Omega I_{2P} \\ 0 & 0 & 0 & C_2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -\Omega I_{2P} & 0 & 0 & 0 \end{bmatrix} \quad (24)$$

$$Q = \begin{bmatrix} K_1 + 6(W+Y) & -6W & 3WL_2 & 0 & 0 & 0 \\ -6W & 6W & -3WL_2 & 0 & 0 & 0 \\ 3WL_2 & -3WL_2 & 4WL_2^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & K_2 + 6(W+Y) & -6W & -3WL_2 \\ 0 & 0 & 0 & -6W & 6W & 3WL_2 \\ 0 & 0 & 0 & -3WL_2 & 3WL_2 & 4WL_2^2 \end{bmatrix} \quad (25)$$

Em (25),

$$W = \frac{2EI}{L_1^3}; \quad Y = \frac{2EI}{L_2^3} \quad (26)$$

$$H = \begin{bmatrix} 0 & 0 \\ m_2 e \Omega^2 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & m_2 e \Omega^2 \\ 0 & 0 \end{bmatrix} \quad (27)$$

Onde e é a excentricidade de massa sobre o centro de rotação do rotor.

Os valores numéricos das variáveis que aparecem nas equações (23) a (27) são atribuídos da seguinte forma:

Tabela 1 - Parâmetros físicos do modelo

Parâmetros	Valor	Unidade
m_1	15	Kg
m_2	10	Kg
I_2	0.25	kg.m ²
I_{2P}	0.20	kg.m ²
$L_1=L_2$	0.4	m
k_1	90.000	N/m
k_2	120.000	N/m
c_1	30.000	kg/s
c_2	37.500	kg/s
Ω	60	rad/s

Supõe-se que a matriz S das entradas em (1) possua a seguinte característica

$$S^T = \{s_1 \ s_2 \ s_3 \ s_4 \ s_5 \ s_6\} \quad (28)$$

sendo s_i ($i=1, \dots, 6$) valores constantes.

Estas variáveis indicam com que intensidade as excitações aleatórias atuam sobre cada coordenada do sistema de equações. A estas variáveis atribui-se os seguintes valores numéricos

Tabela 2 – Valores da Matriz de entradas

Variável	Valor
s_1	1,2
s_2	1,0
s_3	1,0
s_4	1,2
s_5	1,0
s_6	1,0

Para este sistema rotativo específico, as sub-matrizes A_1 and A_2 na Equação (21) tem a seguinte estrutura interna.

$$A_1^T = \begin{bmatrix} k_{11} & k_{12} & k_{13} & 0 & 0 & 0 \\ -k_{22} & k_{22} & k_{23} & 0 & 0 & 0 \\ -k_{32} & k_{32} & k_{33} & 0 & 0 & 0 \\ 0 & 0 & 0 & k_{44} & k_{12} & -k_{13} \\ 0 & 0 & 0 & -k_{22} & k_{22} & -k_{23} \\ 0 & 0 & 0 & k_{32} & -k_{32} & k_{33} \end{bmatrix} \quad (29)$$

$$A_2^T = \begin{bmatrix} c_{11} & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -\Omega I_{2P} \\ 0 & 0 & 0 & c_{44} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \Omega I_{2P} & 0 & 0 & 0 \end{bmatrix} \quad (30)$$

Substituindo (29), (30) em (21) e efetuando algumas manipulações algébricas, chega-se nas equações de compatibilidade do sistema mecânico, onde tais equações contemplam os termos de correlações entre os sinais medidos e os parâmetros físicos do sistema,

$$R_{\xi\xi_{77}}^{\xi\xi} + R_{\xi\xi_{11}}^{\xi\xi} * k_{11} + R_{\xi\xi_{12}}^{\xi\xi} * k_{12} + R_{\xi\xi_{13}}^{\xi\xi} * k_{13} + R_{\xi\xi_{17}}^{\xi\xi} * c_{11} + R_{\xi\xi_{11}}^{\xi\xi} * b_1 = 0 \quad (31)$$

$$R_{\xi\xi_{78}}^{\xi\xi} + R_{\xi\xi_{11}}^{\xi\xi} * k_{22} + R_{\xi\xi_{12}}^{\xi\xi} * k_{22} + R_{\xi\xi_{13}}^{\xi\xi} * k_{23} + R_{\xi\xi_{17}}^{\xi\xi} * e \Omega^2 = 0 \quad (32)$$

$$R_{\xi\xi_{79}}^{\xi\xi} + R_{\xi\xi_{11}}^{\xi\xi} * k_{32} + R_{\xi\xi_{12}}^{\xi\xi} * k_{13} + R_{\xi\xi_{13}}^{\xi\xi} * k_{33} + R_{\xi\xi_{23}}^{\xi\xi} * k_{23} + R_{\xi\xi_{17}}^{\xi\xi} * b_3 = 0 \quad (33)$$

$$R_{\xi\xi_{710}}^{\xi\xi} + R_{\xi\xi_{14}}^{\xi\xi} * k_{44} + R_{\xi\xi_{15}}^{\xi\xi} * k_2 - R_{\xi\xi_{16}}^{\xi\xi} * k_{13} + R_{\xi\xi_{110}}^{\xi\xi} * c_{44} = 0 \quad (34)$$

Os índices $R_{\xi\xi_{ij}}$ indicam a correlação entre a variável de estado i e a variável de estado j . As equações de compatibilidade (31) a (34) tem diferentes dependências sobre os parâmetros. Por exemplo, a Eq.(31) é dependente dos parâmetros k_{11} e c_{11} . Esta equação não é sensível ao parâmetro e relacionado com o desbalanceamento. Esta propriedade é bastante interessante no âmbito de detectar um defeito específico em um componente mecânico relacionado com cada equação e parâmetros correspondes.

As Equações (31) a (34) representam um somatório entre as correlações entre os sinais medidos juntamente com os parâmetros físicos do sistema. De acordo com

Haykin [7], a resposta ou saída de uma rede neural é composta pelo somatório entre as entradas e os pesos sinápticos aplicando uma função de ativação. A idéia básica do sistema de diagnóstico de defeitos em sistemas mecânicos rotativos proposto neste trabalho é fazer a conexão entre estas duas formulações. A partir desta abordagem as Eq. (31 a 34) podem ser modificadas pela seguinte expressão:

$$R_{\xi\xi_{ji}} = f\left(\sum_{i=1}^n R_{in}W_{in}\right) \quad (35)$$

Onde: $R_{\xi\xi_{ij}}$ é a função de correlação de saída do sistema; R_{in} é o conjunto de funções de correlações, correspondendo aos dados de entrada; W_{in} é o conjunto de pesos da camada intermediária, sendo composto pelos parâmetros físicos do sistema e pesos sinápticos; f é chamada de função de ativação(sigmoidal). Os índices $R_{\xi\xi}$ indicam as correlações entre as variáveis de estado i e a variável j .

Neste trabalho adotou-se uma topologia de rede neural composta por três camadas: uma camada de entrada; uma camada intermediária; uma camada de saída, (Haykin, [7]).

Todos os neurônios de cada camada são conectados entre si. Uma representação desta arquitetura é realizada pelo mapeamento nas equações (31) a (34). Representado as mesmas na forma (35) tem-se:

$$R_{\xi\xi_{77}} = f\left(\sum_{i=1}^n R_{in}W_{in}\right) \quad (36)$$

$$R_{\xi\xi_{78}} = f\left(\sum_{i=1}^n R_{in}W_{in}\right) \quad (37)$$

$$R_{\xi\xi_{79}} = f\left(\sum_{i=1}^n R_{in}W_{in}\right) \quad (38)$$

$$R_{\xi\xi_{710}} = f\left(\sum_{i=1}^n R_{in}W_{in}\right) \quad (39)$$

A Figura 5 ilustra a representação da arquitetura neural 1 (Eq. 36). A função de correlação $R_{\xi\xi_{77}}$ é estimada através das correlações entre os sinais medidos dispostos na camada de entrada da rede.




Figura 5. Arquitetura neural para Equação (31)

Estruturalmente, esta rede é composta por três neurônios na camada de entrada correspondendo as funções de correlações $R_{\xi\xi_{11}}, R_{\xi\xi_{12}}$ e $R_{\xi\xi_{17}}$; uma camada intermediária composta pelos parâmetros físicos do sistema $c_{11} \dots k_{11}$ e pesos sinápticos $a_{11} \dots a_{1n}$; e uma camada de saída correspondendo a função de correlação $R_{\xi\xi_{77}}$ que não pode ser estimada diretamente. As correlações associadas com as coordenadas de rotações do rotor $R_{\xi\xi_{13}}$ e do filtro $R_{\xi\xi_{11}}$ foram desconsideradas (Equação (31)).

Com as obtenções das funções de correlações estimadas nas saídas das arquiteturas neurais foram determinados os desvios quadráticos médios (MSD) entre as funções de correlações dos sinais medidos com e sem defeito (Haykin, [7]).

$$MSD = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{\xi\xi_i} - \bar{R}_{\xi\xi_i})^2} \quad (40)$$

onde: $R_{\xi\xi_i}$ é a saída da rede; $\bar{R}_{\xi\xi_i}$ é a saída desejada (Sem defeito); n é o número de dados de treinamento;

Assim, tem-se o interesse em monitorar e diagnosticar o sistema mecânico rotativo mediante uma alteração dos parâmetros físicos do mancal $k_{11}, c_{11}, k_{44}, c_{44}$ presentes nas arquiteturas neurais 1 e 4 (Eq. 36 e 39), e no desbalanceamento do rotor presente na arquitetura 2 (Eq. 37). A arquitetura 3 (Eq. 38) contempla os termos de parâmetros do eixo, em todos os casos que serão estudados estes parâmetros permanecem inalterados.

Para o propósito desse trabalho, o defeito simulado no sistema é representado por uma alteração brusca e permanente no valor numérico de algum parâmetro físico. Em todos os casos estudados, o defeito é representado por uma variação de 20% do valor nominal do parâmetro, sendo utilizado 2048 valores discretos de resposta com tempo de discretização $\Delta t = 2$ ms.

Na Tabela 3 tem-se as condições e os parâmetros físicos sob defeito.

Tabela 3. Condições e parâmetros físicos sob defeitos individuais.

Condições	Parâmetros sob defeito
1	Rigidez k_{11}
2	Amortecimento c_{11}
3	Desbalanceamento
4	Rigidez k_{44}
5	Amortecimento c_{44}

Obtidas as respostas do sistema em condição normal (sem defeito) e condições de defeitos, as respectivas funções de correlações entre os sinais medidos foram calculadas. A partir destas considerações, foram realizadas simulações com o sistema apresentando uma variação no parâmetro k_{11} correspondendo a rigidez do mancal na direção y_1 (Condição 1 da Tabela 3).

Para as estruturas neurais 1 a 4 (Equações 56 a 59) foram analisadas várias configurações de RNA's, onde foram testadas alterações quanto ao número de neurônios da camada intermediária. Esta análise teve como objetivo determinar a convergência dos pesos sinápticos e parâmetros físicos, de tal maneira que esses valores estivessem próximos aos valores reais do modelo.

A Tabela 4 apresenta diversas arquiteturas testadas com os respectivos números de iterações.

Tabela 4. Arquiteturas estudadas e número de iterações

Arquiteturas	Nº de Iterações
Nex3x1	1600
Nex5x1	1500
Nex8x1	1105
Nex10x1	970
Nex12x1	780
Nex15x1	785
Nex20x1	785

Onde **Ne** representa o número de entradas na camada de entrada da rede;

Escolheu-se para todos os casos estudados uma arquitetura de RNA com 12 neurônios na camada intermediária.

Para os propósitos deste trabalho foi implementada uma rede neural usando o *algoritmo de Levenberg-Marquard*, ajustada com as seguintes características: Camada intermediária: função de ativação sigmoideal; Taxa de aprendizado (γ): 0.001; Incremento da taxa de aprendizado = 1.05; Decremento da taxa de aprendizado = 0.60; Momentum: 0.30; Razão de erros: 1.03; Erro total admissível: 0.001

Caso 1: Neste caso o objetivo é analisar o comportamento do sistema mecânico rotativo submetido a uma excitação estocástica do tipo ruído de banda estreita apresentado na seção 2.3. Foram analisadas as mesmas condições propostas na Tabela 5.

Tabela 5. Frequências naturais de excitação x Frequências de corte do filtro

Condições	Freq. Natural de excitação (rad/s)	Frequência de corte f_c (rad/s)
1	99	120
2	179	185
3	203	250
4	348	380
5	443	600

A frequência de corte de **50 rad/s** foi usada para treinamento da rede neural, sendo que as outras frequências foram usadas para testes (Tabela 5).

A Figura 6 apresenta o Gráfico de Bode do sistema rotativo (entrada x_1 e saída y_1) e as respostas do sistema filtro para diferentes frequências de corte.




Figura 6. Diagrama de Bode do Sistema rotativo e resposta do filtro para diferentes frequências de corte.

Para facilitar o entendimento das figuras abaixo se têm as arquiteturas neurais correspondentes a cada equação: **Arquitetura 1** corresponde a Equação 31; **Arquitetura 2** corresponde a Equação 32; **Arquitetura 3** corresponde a Equação 33; **Arquitetura 4** corresponde a Equação 34.

Na Figura 7 tem-se os MSD (Eq. 31) entre as funções de correlações dos sinais medidos para cada arquitetura neural e para as frequências de corte correspondentes para defeitos correspondentes no parâmetro físico k_{11} .

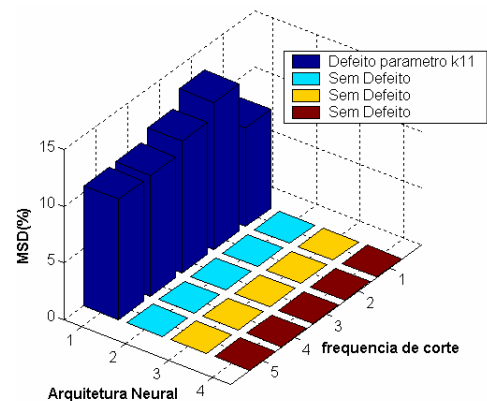


Figura 7. Desvio Quadrático Médio (MSD) para as 4 arquiteturas neurais versus frequências de corte do sistema filtro (Variação de 20% em k_{11})

Obs: As frequências de corte 1 a 5 descritas na Fig. 6, estão indicadas na Tabela 5.

Nota-se que pela Figura 7 correspondendo a Arquitetura Neural 1, uma variação significativa no Desvio Quadrático Médio (10%) com os outros desvios Arquiteturas 2, 3 e 4 na ordem de 10^{-4} . Isto ocorreu pelo fato que essas arquiteturas são insensíveis em relação ao parâmetro k_{11} do mancal.

Na Figura 8 tem-se os Desvios Quadráticos Médios entre as funções de correlações dos sinais medidos para cada arquitetura neural e para as frequências de corte correspondentes para defeitos correspondentes no parâmetro físico c_{11} .

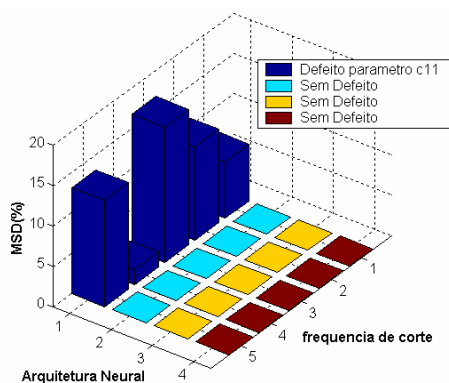


Figura 8. Desvio Quadrático Médio (MSD) para as 4 arquiteturas neurais versus frequências de corte do sistema filtro (Variação de 20% em c_{11}).

Nota-se que pela Figura 8 correspondendo a Arquitetura Neural 1, uma variação significativa no Desvio Quadrático Médio (9%) com os outros desvios Arquiteturas 2, 3 e 4 na ordem de 10^{-4} . Isto ocorreu pelo fato que essas arquiteturas são insensíveis em relação ao parâmetro c_{11} do mancal.

Na Figura 9 tem-se os Desvios Quadráticos Médios entre as funções de correlações dos sinais medidos para cada arquitetura neural e para as frequências de corte correspondentes para defeitos correspondentes no parâmetro físico k_{44} .

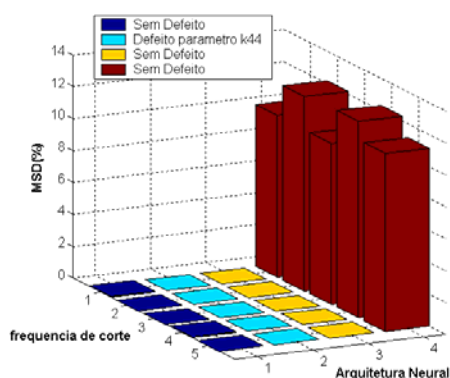


Figura 9. Desvio Quadrático Médio (MSD) para as 4 arquiteturas neurais versus frequências de corte do sistema filtro (Variação de 20% em k_{44}).

Nota-se que pela Figura 9 correspondendo a Arquitetura Neural 1, uma variação significativa no Desvio Quadrático Médio (12%) com os outros desvios Arquiteturas 2, 3 e 4 na ordem de 10^{-4} . Isto ocorreu pelo fato que essas arquiteturas são insensíveis em relação ao parâmetro k_{44} do mancal.

Caso 2: Para testar a viabilidade e a robustez do método proposto, foi estudada a situação em que o sistema mecânico rotativo apresenta defeitos combinados nos parâmetros físicos. Estes defeitos combinados correspondem a uma variação de 20% dos valores de dois parâmetros físicos, mantendo assim os outros parâmetros constantes. Na Tabela 4.5 tem-se as condições e os parâmetros físicos sob defeito.

Tabela 6. Condições e parâmetros físicos sob defeitos combinados

Condições de Defeitos	Descrição do Defeito
1	Redução de 20% k_{11} e k_{44}
2	Redução de 20% c_{11} e c_{44}
3	Redução de 20% k_{11} e desbalanceamento
4	Redução de 20% desbalanceamento e c_{44}

Na Figura 10 tem-se os Desvios Quadráticos Médios entre as funções de correlações dos sinais medidos para cada arquitetura neural e para as frequências de corte correspondentes para defeitos segundo Condição 1, Tabela 6.

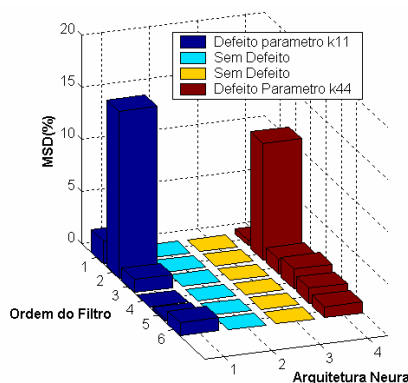


Figura 10. Desvios Quadráticos Médios (MSD) para as 4 arquiteturas neurais versus frequências de corte do sistema filtro.

De acordo com a Figura nota-se variações significativas nos Desvios Quadráticos Médios (12%) nas arquiteturas 1 e 4, com os outros desvios na ordem de 10^{-4} nas arquiteturas 2 e 3. Como era esperado, isto ocorreu pelo fato que essas arquiteturas são insensíveis em relação aos parâmetros k_{11} e k_{44} do mancal.

5 – CONCLUSÕES

O presente trabalho apresenta uma contribuição aos métodos de diagnóstico de defeitos em sistemas mecânicos rotativos. A principal diferença desta proposta em relação às demais metodologias em MBFDI (*Model Based Fault Detection and Isolation*) é a utilização da Equação Matricial de Ljapunov e Redes Neurais Artificiais para monitorar e diagnosticar os parâmetros físicos do sistema sob defeito.

Neste trabalho foi formulada matematicamente uma relação entre os parâmetros do processo e os pesos sinápticos da rede neural a partir das informações das funções de covariâncias dos sinais medidos. Foram feitas comparações entre as funções de correlações teóricas, variando alguns parâmetros da rede neural. Conclui-se que os parâmetros utilizados e o algoritmo influenciam nos resultados finais obtidos.

Em todos os casos estudados os valores dos MSD's tiveram mais evidências, nas arquiteturas relacionadas com os parâmetros sob defeitos.

Um item importante a ser mencionado é que para esta metodologia de diagnóstico de defeitos não há necessidade de se ter o conhecimento numérico real dos parâmetros do sistema, mas se conhecermos a estrutura do modelo e aplicarmos condições de contornos apropriadas certamente se chegará aos objetivos propostos, que é identificar e localizar um determinado tipo de defeito.

REFERÊNCIAS

- [1] Chena, Y.M. and Lee, M.L. "Neural networks-based scheme for system failure detection and diagnosis". Mathematics and Computers in Simulation, pp. 101-109, 2001.
- [2] Eduardo, A.C. – "Diagnóstico de Defeitos em Sistemas Mecânicos Rotativos usando Análise de Correlações e Redes Neurais Artificiais". Tese de Doutorado, Programa de Pós-Graduação em Engenharia Mecânica, Universidade Estadual de Campinas-UNICAMP, SP, 2003.
- [3] Belli, M. R, Conti, M., Crippa, P. and Turchetti, C. "Artificial neural networks as approximators of stochastic processes". Neural Network, pp. 647-658, 1999.
- [4] Miner G.F, D.J. Comer. "Physical Data Acquisition for Digital Processing. Components, Parameters, and Specifications". Prentice-Hall, Englewood Cliffs (NJ), 1992.
- [5] Pederiva, R. "Identificação Paramétrica de Sistemas Mecânicos Excitados Estocasticamente". Universidade Estadual de Campinas, SP. Tese de Doutorado, 1992.
- [6] Melsa, J.L. and Sage, A.P. "An Introduction to Probability and Stochastic Process". Prentice Hall, pp.245-270, 1973.
- [7] Haykin S., "Neural Networks: A comprehensive Foundation". Printice Hall, New Jersey, USA, 2 edition. 1999.