



DIAGNÓSTICO DE FALHAS EM MÁQUINAS ROTATIVAS UTILIZANDO REDES NEURAIAS

Darley Fiácrio de Arruda Santiago

UNICAMP / Faculdade de Engenharia Mecânica – CEFET / Piauí
Caixa Postal 6051 – Campinas – SP – CEP: 13083-970 – darley@fem.unicamp.br

Jorge Nei Brito

Fundação de Ensino Superior de São João Del Rei / Departamento de Engenharia Mecânica
Praça Frei Orlando, 170 - São João Del Rei – MG – CEP: 36307-352 – prof.jnbrito@uol.com.br

Robson Pederiva

UNICAMP / Faculdade de Engenharia Mecânica – Departamento de Projeto Mecânico
Caixa Postal 6051 – Campinas – SP – CEP: 13083-970 – robson@fem.unicamp.br

Resumo

Atualmente técnicas de análise de vibrações sofisticadas estão sendo disponibilizadas para serem utilizadas no monitoramento e diagnóstico de máquinas rotativas complexas. Dentre elas, podemos citar as Técnicas de Inteligência Artificial como Redes Neurais, Lógica Fuzzy, Sistemas Especialistas, etc. As Redes Neurais são ferramentas que tem despertado grande interesse de pesquisadores nos últimos anos. Elas possibilitam o monitoramento on-line da manutenção preditiva visando a minimização do tempo entre o recebimento das informações e o diagnóstico do problema. Neste trabalho mostra-se a capacidade e a viabilidade da aplicação de redes neurais na detecção e diagnóstico de falhas introduzidas numa máquina rotativa. São introduzidas na bancada de testes (eixo-rotor-mancais), as seguintes falhas: defeito elétrico; folga mecânica na base de fixação; desbalanceamento + folga mecânica e desbalanceamento. Várias arquiteturas de redes neurais implementadas com o software Matlab foram treinadas visando a obtenção de uma arquitetura eficiente no diagnóstico das quatro falhas introduzidas na bancada de testes. Resultados mostram que as redes neurais podem ser usadas no diagnóstico de falhas introduzidas numa bancada de testes com eficiência de até 100%.

Palavras-chave: Diagnóstico de Falhas, Máquinas Rotativas, Redes Neurais, Manutenção Preditiva

1. INTRODUÇÃO

A Manutenção Preditiva é uma ciência que usa vários tipos de dados para determinar a condição da máquina e prever uma falha antes que ela ocorra. Os benefícios da manutenção preditiva, em geral, são reduzir o tempo de parada das máquinas, evitar panes, diminuir os custos de manutenção e aumentar a segurança e confiabilidade dos componentes. Este componente pode ser pequeno como um transistor ou pode ser grande como uma usina hidroeétrica (Lin & Wang, 1996) e (Baillie & Mathew, 1996). Atualmente com a sofisticação dos sistemas das máquinas, a manutenção preditiva tem se tornado uma ferramenta viável para o monitoramento e diagnóstico de falhas. A manutenção preditiva depende de investimentos com sensores específicos para monitorar as operações normais e anormais da máquina, bem como analisar esses sinais comparando-os com

dados previamente estabelecidos dentro de uma faixa de tolerância admissível (níveis de alarme). Existem diferentes tipos de métodos de diagnóstico de falhas que podem ser usados, incluindo análise de óleo, análise de vibrações, monitoramento de pressão e temperatura, etc. Por muitos anos, a análise de vibrações tem sido largamente aceita como sendo o método mais confiável de diagnóstico de falhas em máquinas rotativas. Os sinais de vibrações são usados para o monitoramento da condição de máquinas rotativas, diagnóstico de falhas e estimação de severidade.

A detecção e diagnóstico de falhas é geralmente dividida em três estágios (Amand et al., 2001) :

- Detecção – Ocorreu uma falha?
- Identificação – Onde a falha ocorreu?
- Diagnóstico – Por que a falha ocorreu?

A importância da detecção e diagnóstico de falhas em máquinas rotativas cresceu consideravelmente devido ao aumento da sua complexidade e altos custos associados a falha e ao tempo de parada. Normalmente o reconhecimento de falhas requer uma análise detalhada dos sinais das máquinas para identificar padrões de falhas específicas. Tradicionalmente isto é realizado através de inspeção visual e por pessoas experientes em análise espectral ou através de métodos de processamento de sinais. Entretanto, estes métodos são geralmente caros e ineficientes em alguns casos. Atualmente técnicas de análise de vibrações sofisticadas estão sendo disponibilizadas para serem utilizadas no monitoramento e diagnóstico de máquinas rotativas complexas. Dentre elas, podemos citar as Técnicas de Inteligência Artificial como Redes Neurais, Lógica Fuzzy, Sistemas Especialistas, etc. As Redes Neurais são uma das ferramentas que tem despertado grande interesse de pesquisadores nos últimos anos, por ser uma ferramenta que possibilita o monitoramento on-line da manutenção preditiva visando a minimização do tempo entre o recebimento das informações e o diagnóstico do problema (Lucifredi et al., 2000 e Lopes et al., 1998). Inúmeras aplicações utilizando redes neurais no diagnóstico de falhas mecânicas podem ser encontradas nas seguintes referências (Wu et al., 1992; Alguindigue et al., 1993; Chow et al., 1993; Liu et al., 1996; Oliveira, 1999; Zang & Imregun, 2001; Vyas & Satishkumar, 2001 e Brito, 2002).

Neste trabalho mostram-se a capacidade e a viabilidade da aplicação de redes neurais na detecção e diagnóstico de falhas introduzidas numa máquina rotativa. Utilizaram-se para realização deste trabalho, uma bancada de testes do Laboratório de Vibrações da UNICAMP/FEM/DPM e um Analisador de Sinais da CSI (ULTRASPEC 2000). Foram introduzidas na bancada de testes (eixo-rotor-mancais), as seguintes falhas: defeito elétrico; folga mecânica na base de fixação; desbalanceamento + folga mecânica e desbalanceamento.

Várias arquiteturas de redes neurais implementadas com o software *Matlab* foram treinadas visando a obtenção de uma arquitetura bastante eficiente para o diagnóstico das quatro falhas introduzidas. Resultados da aplicação de redes neurais no diagnóstico de falhas de uma máquina rotativa utilizando dados reais são mostrados, bem como seus aspectos práticos e teóricos de implementação.

2. REDES NEURAIS ARTIFICIAIS

Uma rede neural pode ser definida como um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples (neurônios) capazes de armazenar conhecimento experimental e torná-lo disponível para uso futuro (Haykin, 1999).

Um neurônio é uma unidade de processamento de informação imprescindível para o funcionamento de uma rede neural. A Figura (1) mostra o modelo de um neurônio.

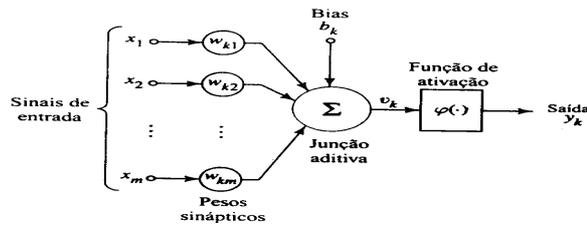


Figura 1. Modelo de um neurônio

O neurônio pode ser representado matematicamente através das seguintes expressões:

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(v_k + b_k) \quad (2)$$

onde:

- x_j : são os sinais de entrada;
- w_{kj} : são os pesos sinápticos;
- v_k : é a saída do combinador linear;
- b_k : é o bias;
- $\varphi(.)$: é a função de ativação;
- y_k : são os sinais de saída do neurônio.

O “bias” b_k aplicado externamente no modelo neuronal, tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, quando ele for positivo ou negativo, respectivamente. As funções de ativação podem ser basicamente de três tipos: função de limiar, função linear e função sigmoideal.

As redes neurais que contém uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, são chamadas de perceptrons de múltiplas camadas (MLP). A Figura (2) mostra a arquitetura de uma rede MLP.

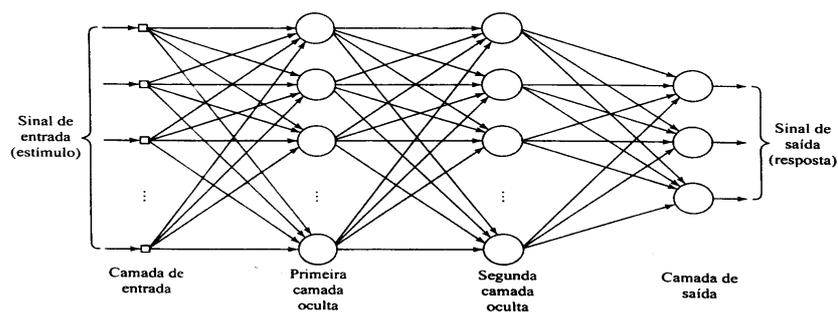


Figura 2. Arquitetura de uma rede neural de múltiplas camadas

Os valores dos pesos sinápticos são determinados pelo treinamento da rede com dados de entrada-saída usando o algoritmo backpropagation que consiste de dois passos através das camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação. No passo para frente, um padrão de entrada ou sinal é propagado através das camadas da rede enquanto os pesos sinápticos são mantidos fixos. Este resultado na saída da rede ou resposta devido ao padrão de entrada é subtraído da resposta desejada e o erro é então propagado para trás através da rede.

Durante este passo os pesos sinápticos são atualizados. Em outras palavras, o algoritmo modifica individualmente os pesos sinápticos até o erro global pré-determinado ser alcançado pela rede. O erro global é calculado através do erro quadrático médio (*E.Q.M*) dado pela seguinte expressão:

$$E.Q.M = \frac{1}{N} \sum_{k=1}^N (y_k - a_k)^2 \quad (3)$$

onde, a_k é a resposta desejada.

Maiores detalhes sobre o algoritmo Backpropagation, Métodos do Gradiente Descendente e Levenberg-Marquardt são encontrados em (Haykin, 1999).

3. RESULTADOS E DISCUSSÃO

Nesta seção apresentam-se alguns resultados obtidos a partir da implementação e treinamento de diversas arquiteturas de redes neurais com o algoritmo backpropagation, utilizando dados reais como parâmetros de entrada da rede. O Toolbox de redes neurais do software Matlab foi utilizado para implementação das redes neurais.

Os dados reais (padrões) utilizados para o treinamento, teste e validação das diversas arquiteturas de redes neurais implementadas foram gerados numa bancada de testes, mostrada na Fig. (3). A bancada consiste de um motor elétrico de 0.5 CV, um rotor fixado ao eixo do motor e suportado em ambas as extremidades por dois mancais de rolamentos, os quais estão fixados na base através de molas flexíveis.

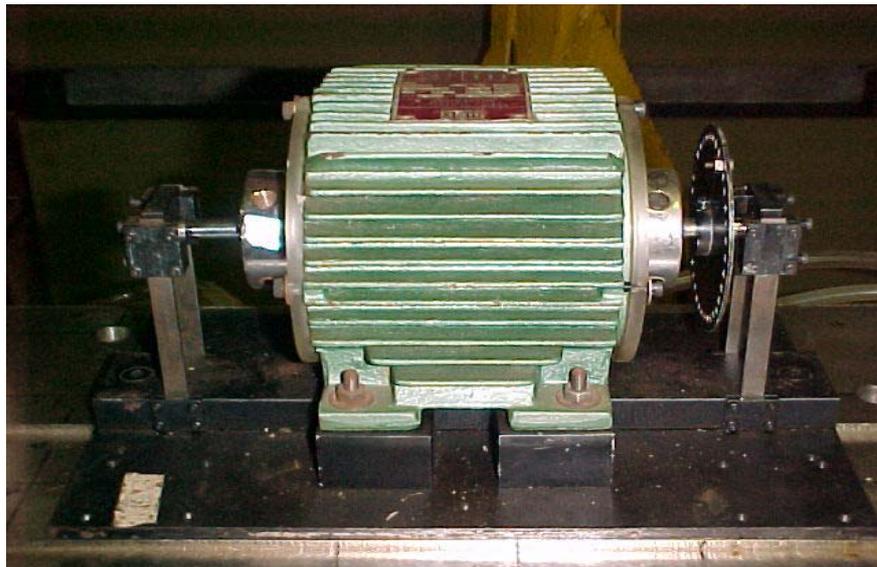


Figura 3. Bancada Experimental de Testes

As falhas foram introduzidas na bancada de testes separadamente, e, em seguida foram feitas as aquisições dos sinais de vibrações (velocidade) utilizando um acelerômetro fixado em um dos mancais posicionado na direção vertical.

A seguir, descreve-se algumas características particulares de cada tipo de falha, bem como se mostra um espectro do sinal medido referente a cada tipo de falha introduzida na bancada de testes.

Defeito Elétrico – Este tipo de falha é bastante comum em máquinas rotativas e pode ser causado basicamente por excentricidade do rotor e linha com voltagem desbalanceada. No segundo caso, este defeito se manifesta, dentre outras características com frequência igual a duas vezes a frequência da linha de alimentação e o plano dominante é o radial com amplitude baixa e

estacionária. O espectro deste sinal coletado durante a fase de aquisição de dados é mostrado na Fig. (4) – (a).

Folga Mecânica – Este tipo de falha foi introduzido na bancada de testes a partir do afrouxamento dos parafusos de fixação entre o motor elétrico e a base da bancada. O espectro deste sinal coletado durante a fase de aquisição de dados é mostrado na Fig. (4) – (b).

Desbalanceamento Vertical + Folga Mecânica – O desbalanceamento foi introduzido na bancada de testes pela fixação de uma massa de 7,8 gramas em um ponto qualquer da extremidade do rotor. A folga mecânica aparece de forma combinada com o desbalanceamento. O espectro deste sinal coletado durante a fase de aquisição de dados é mostrado na Fig. (4) – (c).

Desbalanceamento Horizontal – Este defeito foi introduzido na bancada de testes pela fixação de uma massa de 2.5 gramas em um ponto qualquer da extremidade do rotor e o seu espectro coletado durante a fase de aquisição dos dados é mostrado na Fig. (4) – (d).

Como dito anteriormente, estes quatro tipos de falhas foram introduzidas na bancada de testes separadamente. Para aquisição dos sinais (padrões) referentes as três primeiras falhas (defeito elétrico, folga mecânica e desbalanceamento vertical + folga mecânica), o acelerômetro foi fixado em um dos mancais e posicionado na direção vertical e para o quarto tipo de falha (desbalanceamento horizontal), o acelerômetro foi fixado em um dos mancais e posicionado na direção horizontal.

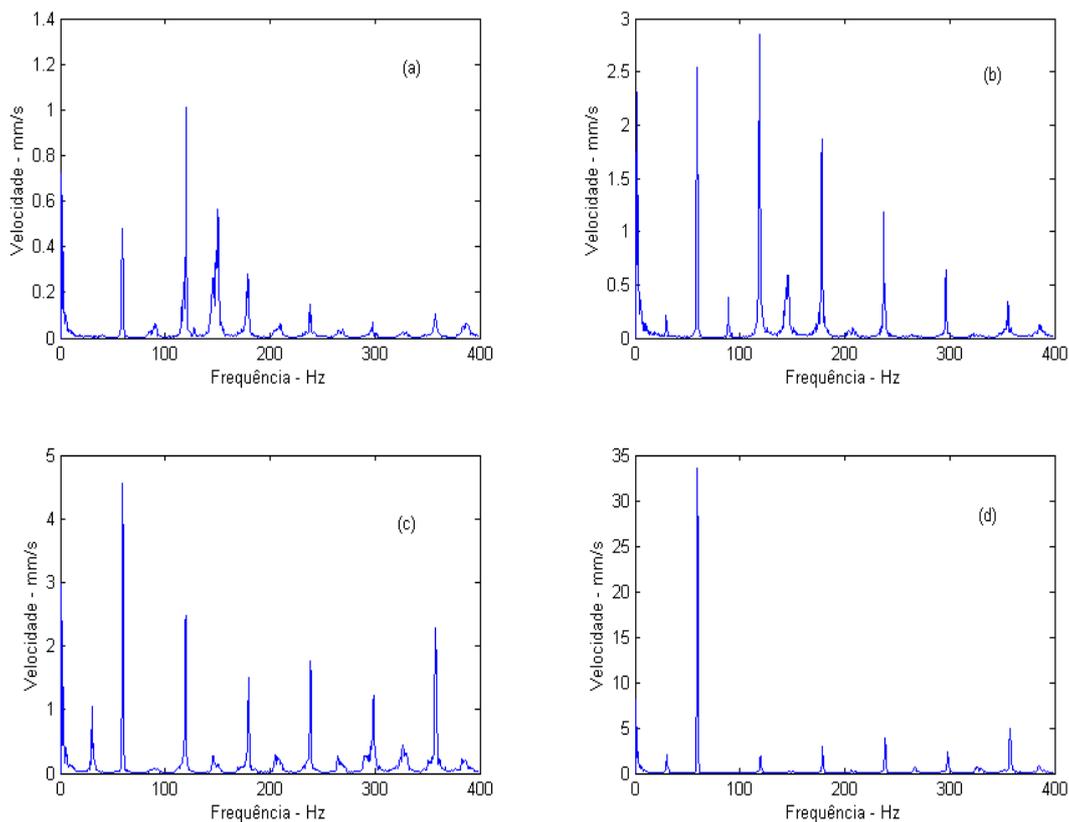


Figura 4. Espectros do Defeito Elétrico (a); Folga Mecânica (b); Desbalanceamento Vertical + Folga Mecânica (c) e Desbalanceamento Horizontal (d).

Foram feitas 80 aquisições (padrões) de sinais de vibrações (velocidade), sendo 20 aquisições para cada tipo de falha. A rotação do rotor foi mantida estacionária em aproximadamente 3600 rpm. A frequência de amostragem dos sinais de vibrações foi de 400 Hz, e, a frequência da linha de alimentação ou da rede é de 60 Hz.

O conjunto de dados reais utilizados para treinamento, teste e validação das arquiteturas de redes neurais implementadas para diagnosticar as quatro falhas introduzidas na bancada de testes foi dividido da seguinte maneira: 40 espectros (padrões) como conjunto de dados de treinamento da rede (sendo 10 padrões para cada tipo de falha); 20 padrões como conjunto de dados de teste da rede (sendo 5 padrões para cada tipo de falha) e 20 padrões como conjunto de dados de validação da rede (sendo 5 padrões para cada tipo de falha).

Utilizaram-se como parâmetros de treinamento de entrada e saída das redes neurais os seguintes dados: Como parâmetros de entrada foram escolhidas as amplitudes dos sinais de cada falha (FRF) correspondentes as frequências em 1xRPM, 2xRPM, 3xRPM, 4xRPM, 5xRPM e 6xRPM e como parâmetros de saída atribuíram-se os seguintes valores (níveis de ativação): 1000 (Defeito Elétrico), 0100 (Folga Mecânica), 0010 (Desbalanceamento Vertical + Folga Mecânica) e 0001 (Desbalanceamento Horizontal).

O objetivo da aplicação de redes neurais num caso real é investigar a sua eficiência e viabilidade como ferramenta de diagnóstico de falhas em máquinas rotativas. Utilizou-se neste trabalho como dados de treinamento 40 FRF's (padrões) com quatro falhas diferentes dispostas de forma aleatória como dados de entrada (amplitudes dos sinais de cada falha (FRF) correspondentes as frequências em 1xRPM, 2xRPM, 3xRPM, 4xRPM, 5xRPM e 6xRPM) e como dados de saída os níveis de ativação correspondentes a cada tipo de falha citados acima.

Durante as fases de implementação, treinamento, teste e validação da rede neural backpropagation foram considerados os seguintes parâmetros de treinamento:

- Camadas de Entrada e Ocultas: Função de Ativação Tangente Hiperbólica;
- Camada de Saída: Função de Ativação Linear;
- Método de Otimização: Levenberg-Marquardt;
- Número de Épocas: 300 Épocas;
- Erro Total Admissível: 1e-5.

Depois de feito o treinamento da rede neural, utilizou-se o seguinte procedimento para teste e validação da mesma rede neural: para o teste da rede utilizaram-se 20 padrões como dados de entrada diferentes dos 40 padrões utilizados durante a fase de treinamento; e para validação da rede utilizou-se 20 padrões como dados de entrada diferentes dos 40 padrões utilizados durante a fase de treinamento e dos 20 padrões utilizados durante a fase de teste.

A seguir, mostra-se na Tab. (1) um resumo dos resultados obtidos com o treinamento de 12 tipos de arquiteturas de redes neurais.

Tabela 1. Resultados das diferentes arquiteturas de redes neurais

<i>Arquitetura da Rede</i>	<i>Nº de Épocas</i>	<i>Tempo de Treinamento</i>	<i>Taxa de Acerto (%) Rede de Teste</i>	<i>Taxa de Acerto (%) Rede de Validação</i>
<i>5x5x4</i>	<i>10</i>	<i>44 seg.</i>	<i>100</i>	<i>75</i>
<i>10x5x4</i>	<i>14</i>	<i>192 seg.</i>	<i>100</i>	<i>100</i>
<i>10x10x4</i>	<i>9</i>	<i>327 seg.</i>	<i>100</i>	<i>95</i>
<i>15x10x5x4</i>	<i>21</i>	<i>15 min.</i>	<i>100</i>	<i>100</i>
<i>5x10x5x4</i>	<i>13</i>	<i>93 seg.</i>	<i>90</i>	<i>100</i>
<i>10x5x5x4</i>	<i>19</i>	<i>295 seg.</i>	<i>100</i>	<i>100</i>
<i>5x5x10x4</i>	<i>11</i>	<i>183 seg.</i>	<i>85</i>	<i>70</i>
<i>5x10x10x4</i>	<i>10</i>	<i>187 seg.</i>	<i>95</i>	<i>60</i>
<i>10x10x10x4</i>	<i>11</i>	<i>421 seg.</i>	<i>100</i>	<i>100</i>
<i>5x5x5x4</i>	<i>49</i>	<i>267 seg.</i>	<i>0</i>	<i>50</i>
<i>10x5x10x4</i>	<i>18</i>	<i>603 seg.</i>	<i>100</i>	<i>100</i>
<i>20x15x10x5x4</i>	<i>14</i>	<i>29 min.</i>	<i>100</i>	<i>100</i>

Observando-se a Tab. (1) chegam-se as seguintes conclusões:

A rede neural com arquitetura 5x5x5x4 (5 neurônios na camada de entrada, 5 neurônios na 1ª camada oculta, 5 neurônios na 2ª camada oculta e 4 neurônios na camada de saída) foi quem apresentou pior taxa de acerto dos sinais (padrões) a ela apresentados, ou seja, dos 20 padrões de testes apresentados a rede ela não reconheceu nenhum padrão e dos 20 padrões de validação apresentados a rede ela reconheceu somente 50% deles.

Em geral, observa-se na Tab. (1) que as demais arquiteturas de redes neurais treinadas foram capazes de diagnosticar com eficiência de 100% as quatro falhas introduzidas na bancada de testes.

Dentre as doze arquiteturas de redes neurais implementadas, a que melhor apresentou capacidade de generalização foi a rede 15x10x5x4. A seguir, mostram-se nas Fig. (5) – (8) resultados satisfatórios de como a rede neural foi capaz de diagnosticar falhas introduzidas numa bancada de testes (máquina rotativa) de forma bastante eficiente.

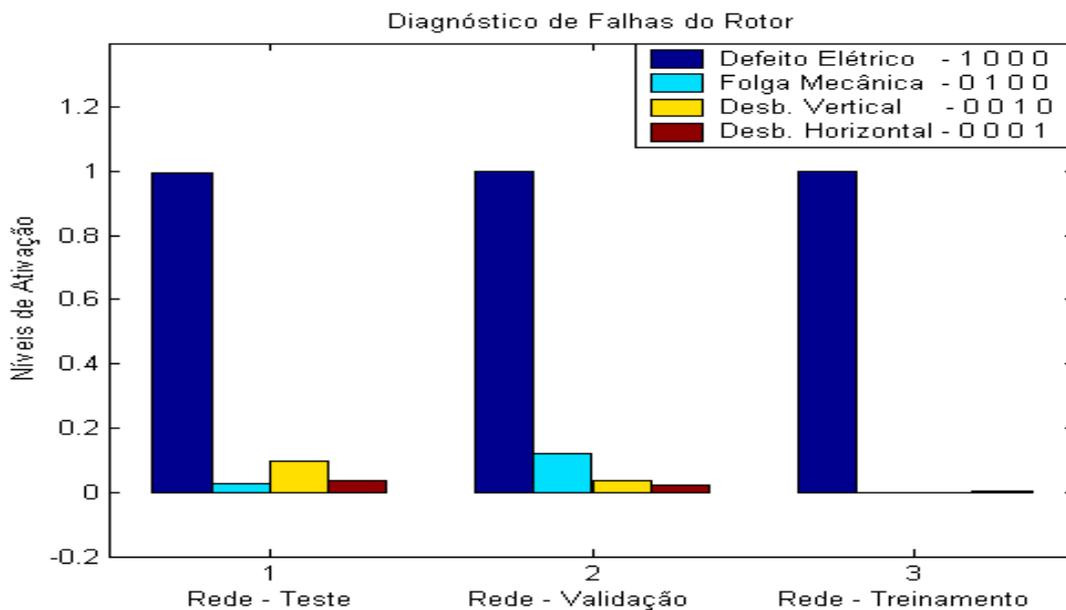


Figura 5. Comparação entre as redes de treinamento, teste e validação – Defeito Elétrico

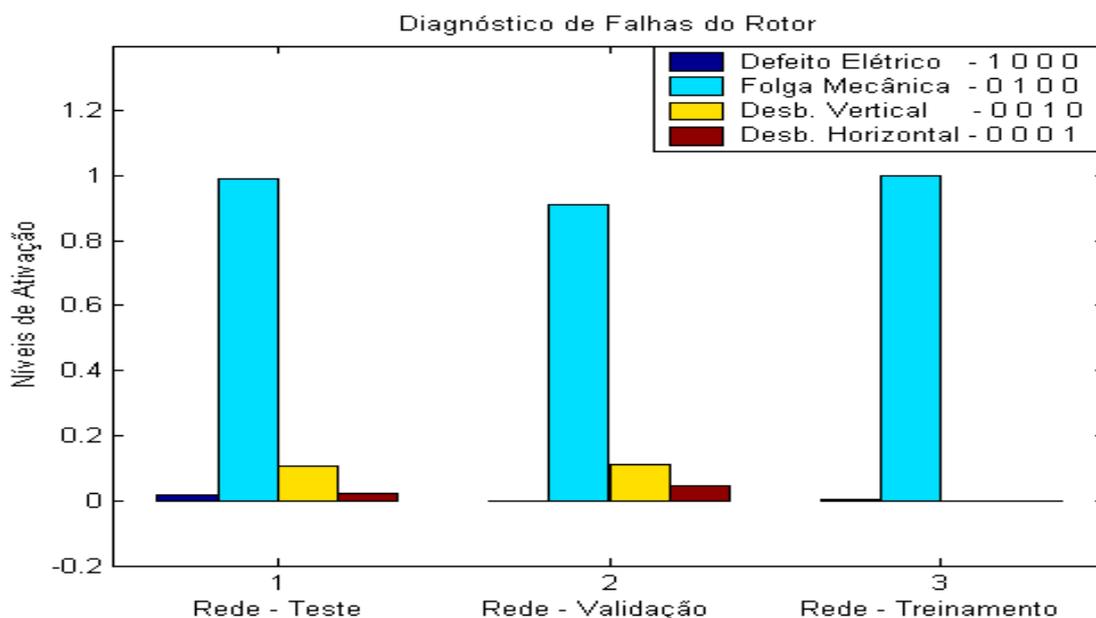


Figura 6. Comparação entre as redes de treinamento, teste e validação – Folga Mecânica

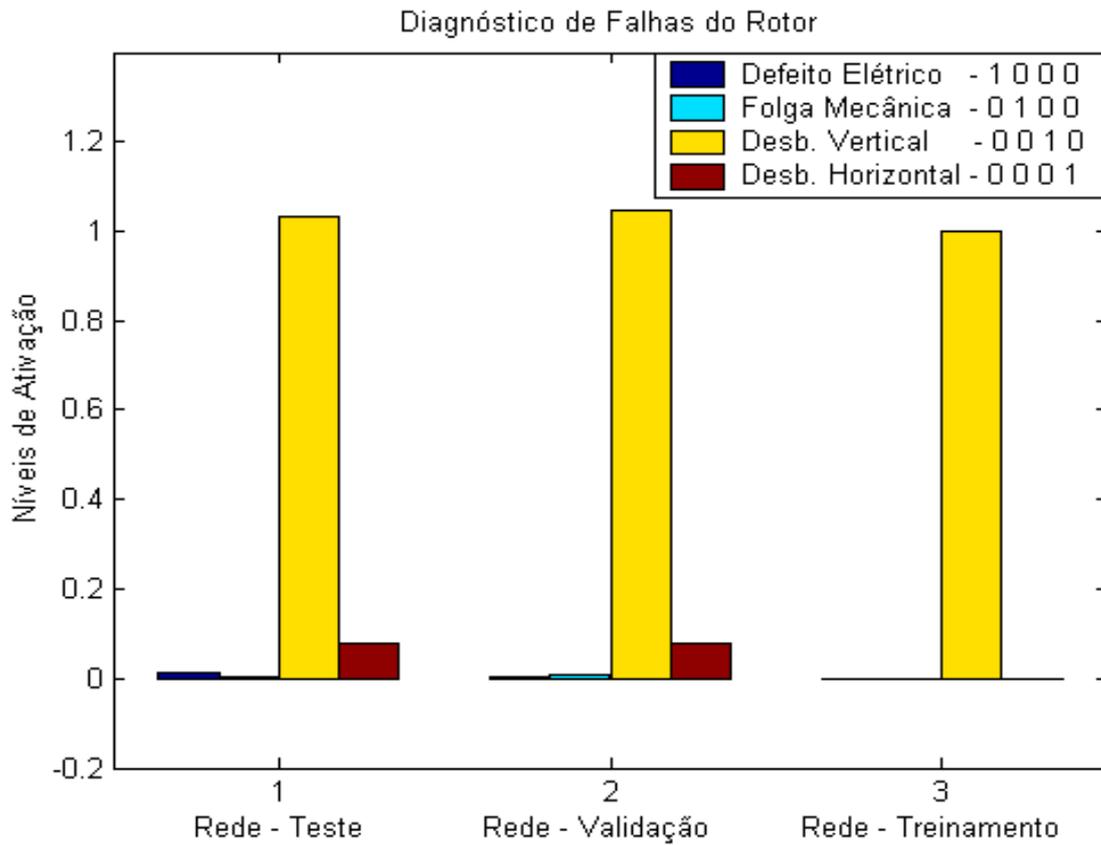


Figura 7. Comparação entre redes de treinamento, teste e validação – Desb. Vert. + Folga Mecânica

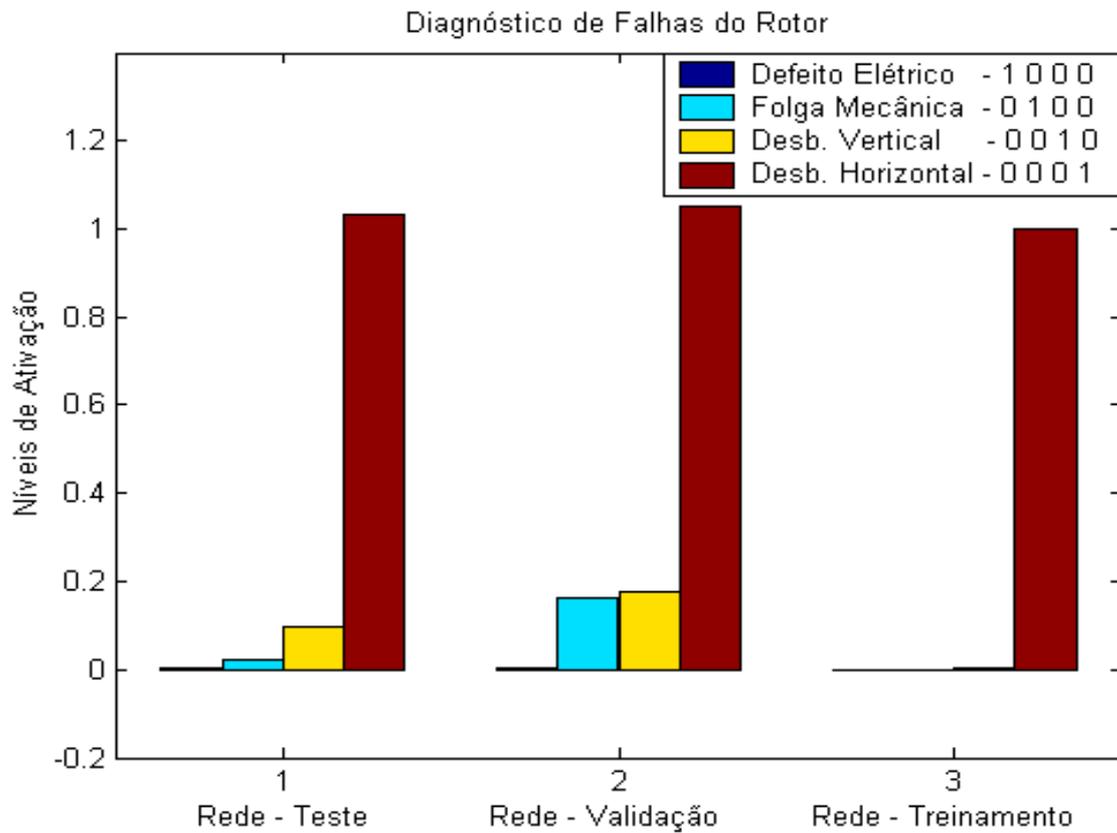


Figura 8. Comparação entre as redes de treinamento, teste e validação – Desb. Horizontal

4. CONCLUSÕES

As Redes Neurais são uma das ferramentas que tem despertado grande interesse de pesquisadores nos últimos anos, por ser uma ferramenta que possibilita o monitoramento on-line da manutenção preditiva visando a minimização do tempo entre o recebimento das informações e o diagnóstico do problema.

Diante dos resultados apresentados, observou-se que: Dentre muitos aspectos teóricos e práticos que fazem parte de um projeto de rede neural, a escolha de uma arquitetura de rede neural e de seus parâmetros de treinamento não segue regras predefinidas; O conhecimento e experiência do projetista em relação ao problema enfrentado são mais importantes; A fase de definição é delicada, pois envolve, além da escolha da topologia da rede, a obtenção do conjunto de variáveis significativas para resolução do problema. Essa obtenção envolve, além da identificação das variáveis que estão relacionadas com o problema, a remoção de variáveis não confiáveis para o processo, ou cujo uso seja impraticável por razões técnicas e econômicas.

Adicionalmente, observou-se que a sensibilidade e o tempo de resposta das redes neurais em relação a outras técnicas de diagnóstico de falhas são aspectos importantes e que podem ser avaliados e melhorados durante as fases de implementação, treinamento, teste e validação da rede neural.

Finalmente, resultados mostram a partir de um caso real, a capacidade e viabilidade da aplicação de redes neurais como ferramenta bastante eficiente na detecção e diagnóstico de falhas introduzidas numa máquina rotativa.

5. REFERÊNCIAS

- Alguidingue I. E., Buczak A. L., Uhrig R. E., 1993, "Monitoring and Diagnosis of Rolling Element Bearings Using Artificial Neural Networks", IEEE Transactions on Industrial Electronics, Vol. 40:(2), 209-217, April.
- Amand Th., Heyen G., Kalitventzeff B, 2001, "Plant Monitoring and Fault Detection Synergy Between Data Reconciliation and Principal Component", Computers and Chemical Engineering Vol. 25, pp.501-507.
- Baillie D. C., Mathew J, 1996, "A Comparison of Autoregressive Modeling Techniques for Fault Diagnosis of Rolling Element Bearing", Mechanical Systems and Signal Processing, Vol. 10, No. 1, pp.1-17.
- Brito J. N., 2002, "Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos", Tese de Doutorado, Universidade Estadual de Campinas.
- Chow M.-Y., Sharpe R. N., Hung J. C, 1993, "On The Application and Design of Artificial Neural Networks for Motor Fault Detection – Part II", IEEE Transactions on Industrial Electronics, Vol. 40:(2), 189-196, April.
- Haykin S., 1999, "Redes Neurais – Princípios e Prática", Prentice Hall.
- Lin C.-C., Wang H.-P, 1996 "Performance Analysis of Rotating Machinery Using Enhanced Cerebellar Model Articulation Controller (E-CMAC) Neural Networks", Computers Ind. Engng., Vol 30, No. 2, pp. 227-242.
- Liu T. I., Singonahalli J. H., Iyer N. R., 1996 "Detection of Roller Bearing Defects Using Expert System and Fuzzy Logic", Mechanical Systems and Signal Processing, 10:(5), 595-614.
- Lopes A. P., Andrade O. P., Vianna A. L., 1998, "Sistemas Inteligentes na Manutenção Preditiva", T&N Petróleo, pp. 53-55.
- Lucifredi A., Mazziere C., Rossi M., 2000, "Application of Multiregressive linear Models, Dynamic Kriging Models and Neural Network Models to Predictive Maintenance of Hydroelectric Power Systems", Mechanical Systems and Signal Processing, Vol. 14, No. 3, pp. 471-494.
- Oliveira A. G., 1999, "Técnicas de Caracterização de Excitações em Máquinas Rotativas", Tese de Doutorado. Universidade Federal de Uberlândia.

- Vyas N. S., Satishumar D., 2001, "Artificial Neural Network For Fault Identification In a Rotor-Bearing System", *Mechanism and Machine Theory*, 36, 157-175.
- Wu X., Ghaboussi J., Garret-Jr J. H, 1992, "Use of Neural Networks In Detection of Structural Damage", *Computers & Structures*, 42:(4), 649-659.
- Zang C., Imregun M., 2001, "Structural Damage Detection Using Artificial Neural Networks and Measured FRF Data Reduced Via Principal Component Projection", *Journal of Sound and Vibration*, 242:(5), 813-827.

FAULTS DIAGNOSIS OF ROTATING MACHINERY USING NEURAL NETWORKS.

Darley Fiácrio de Arruda Santiago

UNICAMP / Faculty of Mechanical Engineering – CEFET / Piauí
PO 6051 – Campinas – SP – CA: 13083-970 – darley@fem.unicamp.br

Jorge Nei Brito

FUNREI / Department of Mechanical Engineering
170, Frei Orlando Sq. - São João Del Rei – MG – CEP: 36307-352 – prof.jnbrito@uol.com.br

Robson Pederiva

UNICAMP / Faculty of Mechanical Engineering – Department of Mechanic Design
PO 6051 – Campinas – SP – CA: 13083-970 – robson@fem.unicamp.br

Abstract

Recently sophisticated vibration monitoring techniques have been available to be used in the monitoring and diagnostics of complexes rotating machinery. Among them, can relate the artificial intelligence techniques as neural networks, fuzzy logic, expert systems and so on. The neural networks are tools that have woken up a lot of interest on researchers in the last years. They let the monitoring on-line of predictive maintenance aiming the minimization of the time between the receiving of the informations and the diagnosis of the problem. This paper shows the ability and feasibility of the application of neural networks in the diagnostic of faults inserted in the rotating machinery. In the experimental set-up (shaft-rotor-bearings) are inserted the following faults: defect electric, looseness, unbalance + looseness and unbalance. Several architectures of neural networks implemented with the Matlab Software were trained to provide the best architecture to diagnostic of four faults inserted in the experimental set-up. Results show that the neural networks can be effectively used in the diagnostic of faults inserted in the experimental set-up with a 100% performance.

Keywords: *Fault Diagnosis, Rotating Machinery, Neural Networks, Predictive Maintenance.*