



2º CONGRESSO BRASILEIRO DE P&D EM PETRÓLEO & GÁS

AVALIAÇÃO DA CONDIÇÃO MECÂNICA DE TURBOMÁQUINAS PELA ASSINATURA ESPECTRAL DA VIBRAÇÃO E REDES NEURAIS

Samuel T. Adejoro, Tiago A. P. Lopes, João M. A. Rebello

COPPE / Universidade Federal do Rio de Janeiro
Caixa Postal 68508 CEP 21945-970 Rio de Janeiro RJ Brasil
E-mail: samuel@peno.coppe.ufrj.br

Resumo - A manutenção preditiva tem como premissa básica o acompanhamento da condição/integridade mecânica das máquinas rotativas através da avaliação das características de diversos tipos de parâmetros, sendo a vibração o mais utilizado. Este trabalho apresenta uma aplicação de redes neurais na identificação de defeitos mecânicos em turbomáquinas através da avaliação da assinatura espectral de vibrações, nas direções radial e axial. Visto que a assinatura espectral possui um grande número de ordenadas, foi considerada a sua subdivisão em faixas previamente selecionadas e calculada a vibração média em cada uma destas faixas. Na fase inicial do trabalho, foram selecionados nove defeitos típicos que podem ocorrer neste tipo de máquina, sendo os dados para treinamento gerados a partir de variações aleatórias no entorno de padrões típicos encontrados na literatura. Foram utilizadas três tipos de rede: MLP (*Multi Layer Perceptron*), MLP com entrada de dados tipo fuzzy e SOM (*Self Organizing Map*). Os resultados demonstram a capacidade dos diversos tipos de rede realizarem a identificação dos defeitos, destacando-se a MLP com dados de entrada tipo fuzzy e a SOM.

Palavras-chave - manutenção preditiva, vibração, turbomáquina, redes neurais

Abstract - The condition monitoring of machinery generally considers the vibration signature as the main parameter to be measured and is one of the bases of predictive maintenance. The mechanical condition/integrity evaluation can be performed by comparing the measured spectrum to a reference spectrum and is based on the premise that usually exist spectral characteristics that identifies the fault. Nine typical faults are considered and the automation of the capability to interpret the vibration data is a field for the application of artificial neural networks. This article presents a comparative study for three types of neural networks: MLP, *fuzzy*-MLP and SOM for turbomachinery mechanical faults classification. The mean standards for the faults were obtained from available literature and random changes were introduced in order to establish the training data for the neural networks.

Keywords - predictive maintenance, vibration, turbomachinery, neural networks

1. Introdução

A avaliação da condição pela assinatura da máquina utiliza o espectro de vibração, com as suas componentes de frequência, para cada ponto de medição escolhido, consistindo em um gráfico tipo nível de vibração x frequência. O acompanhamento do estado mecânico de uma máquina é obtido pela comparação do espectro de vibração em um determinado instante com um espectro de referência, normalmente obtido com a máquina nova ou recém saída de uma revisão geral, denominado espectro de referência da condição mecânica.

O diagnóstico por vibração tem como objetivo detectar um problema mecânico e a sua origem, a partir de um quadro de sintomas determinado pelas características da vibração. A análise por assinatura de vibração é um dos métodos mais aplicados atualmente na identificação de falhas. A sua premissa básica é de que existem certas características espectrais que, em termos gerais, identificam determinados tipos de defeitos (Rezende, 1991). Esta técnica tem se constituído em uma metodologia de grande valia para a manutenção preditiva de máquinas rotativas. Atualmente, um passo essencial para a manutenção preditiva é o aperfeiçoamento e a automação da capacidade de interpretação dos dados de vibração, representando um vasto campo para aplicação das técnicas de inteligência artificial, principalmente redes neurais e sistemas *fuzzy* (Lopes, 1997).

As redes neurais artificiais surgiram a partir de modelos biológicos, na tentativa de simular o modo de processamento do cérebro humano. Essa técnica possui a capacidade de extrair relações ou adquirir 'conhecimento' a partir de uma massa de dados coletada. Para isso, a rede passa por uma fase de treinamento, onde são utilizados os chamados algoritmos de aprendizado (Haykin, 1994). A teoria dos conjuntos *fuzzy* surgiu com o objetivo de processar incertezas inerentes a maioria dos problemas práticos. São as chamadas incertezas linguísticas. Os conjuntos *fuzzy* podem ser aplicados de diversas maneiras, associados às redes neurais, possibilitando, em muitos casos, um melhor desempenho na classificação dos defeitos (Cox, 1998) e (Uhrig, 1993).

Este trabalho busca demonstrar a capacidade de aprendizado das redes neurais na interpretação de sinais de vibração de turbo-máquinas, através da utilização de três tipos de enfoque do problema:

- uma rede do tipo *Multilayer Perceptron* (MLP);
- um sistema híbrido, utilizando uma MLP com dados de entrada tipo *fuzzy*.
- uma rede do tipo *Self-Organizing Map* (SOM);

2 Vibração em Turbomáquinas

De maneira geral, são consideradas turbomáquinas os equipamentos acionados por turbinas e que funcionam em regime de alta rotação. São, geralmente, de grande porte e elevado grau de importância nos processos produtivos. Estão neste grupo as turbinas a vapor e a gás, os compressores centrífugos e axiais e turbogeradores. Estas máquinas estão presentes, entre outros, em indústrias petroquímicas e plataformas de petróleo.

Através da vibração é possível a detecção e identificação de uma série de problemas de origem mecânica ou dinâmica da máquina. Podem ser destacados os seguintes problemas: desbalanceamento, desalinhamento (pré-carga), instabilidade de filme de óleo (*oil whirl*), instabilidade de atrito (*friction whirl*), roçamento, problemas de mancal, problemas de acoplamento e carcaça ou suporte frouxos.

As faixas de frequência consideradas como de interesse para a discriminação dos defeitos relacionados são as seguintes: 0~40% da Frequência de Rotação (FR), 40-55% da FR, 55~90% da FR, 90~110% da FR (1xFR), 190~210% da FR (2xFR) e 290~310%+390~410%+490~510% da FR (nxRF)

Existem diversas de processar os sinais de vibração que poderiam auxiliar na obtenção de um diagnóstico mais seguro. Alguns trabalhos atuais sugerem a compressão de dados a partir do histórico temporal e espectral da máquina, utilizando algoritmos de extração de características como, por exemplo, a Análise de Componentes Principais ou Algoritmos Autoregressivos (Boyce, 1998). Esses algoritmos reduzem a dimensão do vetor de entrada da rede minimizando a perda de informações importantes.

No presente trabalho, as variáveis para entrada das redes neurais para classificação de defeitos serão oito, divididas da seguinte forma:

- 6 (seis) entradas relacionadas às faixas de frequência do espectro;
- 2 (duas) entradas correspondentes à quantificação da vibração nas direções radial e axial.

Para o treinamento do classificador neural, necessitamos de um conjunto de dados onde o tipo de padrão já esteja correlacionado com o defeito. No diagnóstico por vibração, esses dados devem ser obtidos a partir de situações que melhor representam o real comportamento dos diversos tipos de equipamentos. Dados de campo são geralmente escassos, o que sugere a utilização de dados artificialmente criados a partir de Modelos de Elementos Finitos e de Simuladores de Falhas (Mitchel, 1993). No presente trabalho, optou-se pela geração dos dados de treinamento a partir de variações no entorno das distribuições espectrais características dos defeitos escolhidos. Tal opção é baseada nos seguintes argumentos:

- as distribuições espectrais características das falhas representam anos de experiência de técnicos e engenheiros e devem ser levadas em conta mesmo em sistemas de classificação mais apurados;

- o espectro típico de um defeito (padrão do defeito), como o próprio nome diz, representa o espectro mais comum, por isso, mais provável em uma larga gama de espectros que um defeito pode apresentar;
- a geração de um conjunto de dados tendo como base variações aleatórias com relação a cada padrão médio é uma forma de gerar os conjuntos de dados para o treinamento da rede neural, de modo que o classificador adquira a robustez necessária para a realização eficiente da sua função.

A tabela 1 apresenta os defeitos com seus respectivos padrões, nas faixas de frequência de interesse, e a relação de vibração nas direções axial e radial, após reescalados, sendo considerados desbalanceamento(1), roçamento(2), desalinhamento angular(3), desalinhamento paralelo(4), mancal defeituoso(5), mancal ou suporte frouxos(6), acoplamento defeituoso(7), *whirl* por atrito(8) e *whirl* por óleo(9). As oito informações de entrada para o classificador compõem o vetor-padrão do defeito. Estes dados foram extraídos de (Mitchel, 1993).

Tabela 1. Padrão médio dos defeitos considerados

Defeito	0-40	40-55	55-90	1xRF	2xRF	nxRFr	Radial	Axial
1	0	0	0	0,9	0,05	0,05	0.9	0.1
2	0,11	0,22	0,11	0,22	0,11	0,22	0.7	0.3
3	0	0	0	0,4	0,5	0,1	0.4	0.6
4	0	0	0	0,4	0,5	0,1	0.6	0.4
5	0,09	0,06	0,05	0,3	0,2	0,3	0.7	0.3
6	0,6	0,4	0	0	0	0	0.9	0.1
7	0,1	0,2	0,1	0,2	0,3	0,1	0.7	0.3
8	0,8	0,1	0,1	0	0	0	0.9	0.1
9	0	0,7	0	0,3	0	0	0.9	0.1
10								
11								
12								

3. Geração dos Conjuntos de Treinamento

Os dados foram gerados a partir de variações aleatórias nos componentes dos vetores-padrões dos diferentes defeitos. Pelo gráfico da figura 1 podemos notar que a inserção de um ruído aleatório gera variações em torno do vetor-padrão até o ponto em que ele começa a ser desfigurado, perdendo a capacidade de caracterizar o defeito. Como os dados gerados devem se aproximar da melhor forma possível os dados experimentais, a inserção de ruído obedece ao critério de variação do vetor-padrão em todas as suas componentes, considerando o peso de cada componente.




Figura 1. Variação do padrão de desbalanceamento

O procedimento de inserção de ruído nos padrões dos defeitos foi feito, basicamente, pela adição de um vetor de números aleatórios. Sabendo-se que as seis primeiras componentes dos padrões correspondentes à relação de componentes em frequência que possui somatório unitário, a definição do nível de ruído inserido foi feita simplesmente pelo somatório das componentes do vetor-ruído. Por exemplo, 20% de ruído significa que foi inserido um vetor aleatório, cujo o somatório de componentes foi de 0.2. Este mesmo procedimento foi adotado para as duas últimas componentes de um vetor-padrão, pois os ruídos foram inseridos de forma independente nos dois casos. Para o treinamento dos diferentes classificadores neurais foram gerados 450 exemplos, sendo 50 exemplos para cada defeito. Para o conjunto de teste foram gerados 270 exemplos distribuídos em quantidades iguais entre os padrões. O conjunto

de avaliação (conjunto utilizado para avaliação do desempenho dos classificadores em fase pós-treinamento), foi criado a partir da geração de 50 exemplos para cada padrão de defeito.

Durante o processo de avaliação preliminar, para efeito de comparação entre as configurações de rede adotadas, foi calculado o erro de classificação sobre todo o conjunto de avaliação para cada configuração considerada. Esse erro foi obtido a partir da seguinte fórmula:

$$E = \sum_{i=1}^{450} \sqrt{\frac{1}{9} \sum_{j=1}^9 (Desejada_{ij} - Rede_{ij})^2} \quad (1)$$

onde:

$Desejada_{ij}$ = resposta desejada para o exemplo i com relação à classe j ;

$Rede_{ij}$ = resposta da rede para o exemplo i com relação à classe j ;

$1 \leq i \leq 600$ = número de exemplos do conjunto de avaliação;

$1 \leq j \leq 12$ = número de classes na saída da rede.

4. Desempenho das Redes Neurais

Após uma série de avaliações, a configuração escolhida para o classificador MLP, com oito parâmetros de entrada, foi a seguinte: 10 x 15 neurônios intermediários e 9 neurônios na saída.

No caso da rede *fuzzy*-MLP, para cada componente do vetor de entrada (por exemplo 1xRF), foram criadas 3 funções de pertinência, de formato triangular, representado três conjuntos lingüísticos possíveis (ex., "Alta 1xRF", "Média 1xRF" e "Baixa 1xRF"). Com isso, o número de entradas da rede passa de 8 para 24 entradas (3x8). Esse procedimento processa a informação de modo a pré-classificar cada uma das oito componentes do vetor-padrão nos conjuntos "Alta", "Média" ou "Baixa", reduzindo a importância das pequenas variações nos valores numéricos destas componentes para o classificador. Após uma série de avaliações, a configuração escolhida para o classificador *fuzzy*-MLP, com oito parâmetros de entrada, foi a seguinte: 25 x 35 neurônios intermediários e 9 neurônios na saída.

No caso da rede SOM, os parâmetros de treinamento foram especificados a partir de uma série de avaliações práticas e são os seguintes: 10 x 10 x 10 neurônios.

5. Resultados

Os resultados estão apresentados sob forma gráfica, tendo sido utilizados 50 vetores de *recall* para cada um dos defeitos considerados. Para a interpretação dos gráficos, deve se considerar que caso todas as classificações fossem perfeitas, os círculos referentes a cada um dos defeitos teriam todos a mesma cor. Por exemplo, caso todos os casos de desbalanceamento tivessem sido perfeitamente classificados, todos os 50 círculos seriam totalmente vermelhos. No caso de um círculo possuir uma parte da cor de outra classe, a relação entre as áreas é proporcional ao acerto na classificação.

Rede MLP

Na figura 2 estão apresentados os resultados iniciais obtidos para a rede MLP. Podemos observar, neste gráfico, que a rede não alcançou uma separação adequada para diversas classes: "desalinhamento angular", "desalinhamento paralelo", "roçamento", "mancal defeituoso", "acoplamento" e "roçamento selagem", no total de 12 classificações erradas em um total de 600 dados de entrada (erro=2%).

Rede *fuzzy*-MLP

Na figura 3 estão apresentados os resultados iniciais para a rede *fuzzy*-MLP. Comparando-se estes resultados de classificação com o da rede MLP, observamos que houve menor dificuldade para a classificação dos defeitos de uma maneira geral, pois todos os conjuntos foram classificados corretamente. A rede *Fuzzy*-MLP é capaz de classificar vetores que estão situados em região próxima da fronteira de classes de uma forma mais suave, isto é, uma pequena variação no exemplo não causa uma mudança brusca de classe. Este tipo de classificação se aproxima melhor do comportamento do ser humano que não promove uma classificação do tipo sim ou não.

Rede SOM

Podemos ver também no gráfico da figura 3, que a rede SOM, da mesma forma que a rede *fuzzy*-MLP, conseguiu compor uma fronteira de classes bem definida para todos os defeitos considerados. É importante ressaltar que a saída da rede SOM, assim como das redes anteriores, foi considerado binária (0,1), implicando em que os círculos têm apenas uma cor, sendo que esta hipótese, do ponto-de-vista do diagnóstico, não considera todas as possíveis falhas que o exemplo pode representar. No gráfico da figura 4 está apresentado um mapeamento 3-D, com a indicação da organização dos conjuntos que representam os diversos tipos de defeitos.

6. Conclusões

Este trabalho teve por objetivo aplicar técnicas de redes neurais ao diagnóstico de falhas mecânicas características de turbomáquinas. A capacidade de cada tipo de rede neural classificar os diversos defeitos foi demonstrada, através da sua capacidade de aprendizado e do seu comportamento em diversas situações de classificação. Foram abordados três tipos de classificadores neurais: uma rede do tipo MLP, uma rede que incorpora o conceito de números *fuzzy* à uma rede MLP e uma rede tipo SOM, tendo sido verificado que a rede com o melhor desempenho é a do tipo *fuzzy*-MLP. Embora os dados utilizados para o treinamento das redes tenham sido obtidos a partir de variações de valores típicos para os diversos defeitos estudados, esta metodologia não está em desacordo com o aspecto demonstrativo do presente trabalho.

7. Agradecimentos

8. Referências

- BOYCE, J et ALL Pump Motor Vibration analysis and Fault Detection using Artificial Neural / Fuzzy System, Proceedings EUFIT, p.126-131, 1998
- COX, C, EMMANOUILIDIS, C and MACINTYRE, J An Integrated, Soft Computing Approach for Machine Condition Diagnosis, Proceedings EUFIT, p.145-150, 1998
- HAYKIN, S *Neural Networks*, Macmillan College Publishing Co., 1994
- MITCHEL, J S, *Turbomachinery Analysis and Monitoring*, PennWell Books, 1993
- REZENDE, J C F Manutenção Preditiva em Turbomáquinas utilizando Sistemas Especialistas na Análise de Vibração, Tese Ms.c. COPPE/UFRJ, 1991
- LOPES, T A P & TROYMAN, A C R *Neural Networks on the Predictive Maintenance of Turbomachinery*, Proceedings IFAC, p.988-993, 1997
- UHRIG, R E et ALL (1993) *Hybrid Neural Network - Fuzzy Logic Diagnosis System for Vibration Monitoring*, Proceedings ANNIE, p.467-472, 1993




Figura 2. Rede MLP / resultado final do conjunto de avaliação




Figura 3. Rede *fuzzy*-MLP e SOM / Resultado final do conjunto de avaliação

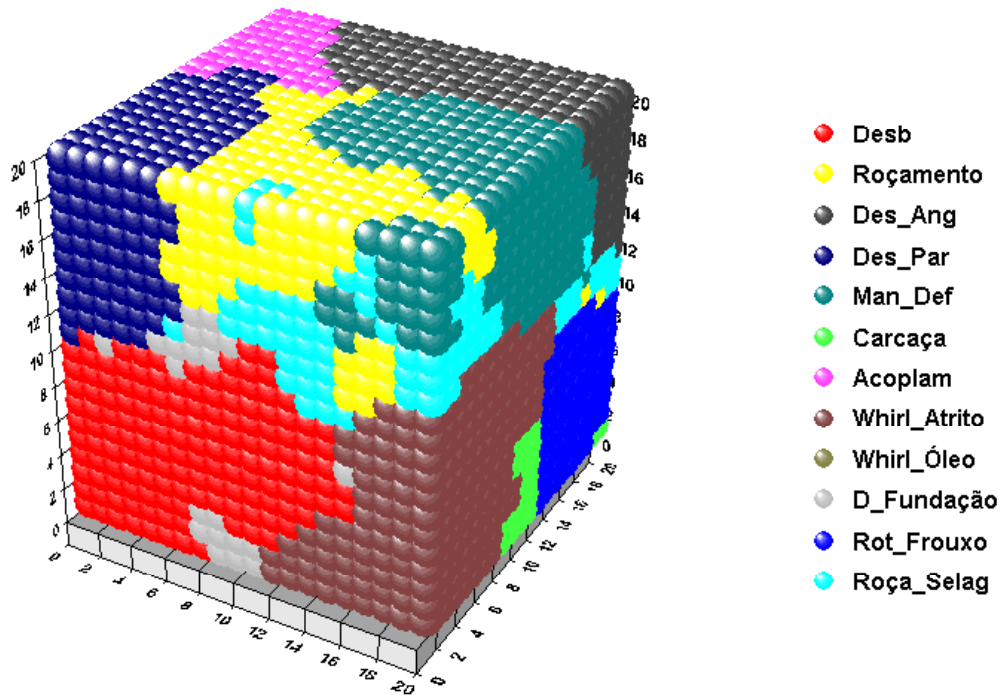


Figura 4. Rede SOM / mapeamento 3-D do conjunto de avaliação