

ESPECTRO DE VIBRAÇÃO E REDES NEURAIS NA IDENTIFICAÇÃO DE FALHAS EM TURBOMÁQUINAS

Tiago Alberto Piedras Lopes

COPPE/UFRJ Centro de Tecnologia Rio de Janeiro RJ
tiago@peno.coppe.ufrj.br

Antonio Carlos Ramos Troyman

COPPE/UFRJ Centro de Tecnologia Rio de Janeiro RJ
troy@peno.coppe.ufrj.br

Samuel Taiwo Adejoro

COPPE/UFRJ Centro de Tecnologia Rio de Janeiro RJ
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, que apresenta o melhor desempenho.*

Palavras-chave: *turbomáquinas, manutenção preditiva, espectro de vibração, redes neurais*

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, conforme Mitchel (1993).

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, de acordo com 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*, conforme proposto por (Boyce et al, 1998, Parikh et al, 1999, Sohn et al, 2000, He et al, 2001, Hoffman et al, 2001, MaLauchlan et al, 2001 e Balazinski et al, 2002).

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, descritos por Haykin (1994). A teoria dos conjuntos *fuzzy* surgiu com o objetivo de processar incertezas inerentes a maioria dos problemas práticos. São as chamadas incertezas lingüísticas. Os conjuntos *fuzzy* podem ser aplicados de diversas maneiras, associados às redes neurais, possibilitando, em muitos casos, um melhor desempenho na classificação dos defeitos, conforme (Cox, 1998 e Uhrig, 1993).

Este trabalho busca demonstrar a capacidade de aprendizado das redes neurais na interpretação das assinaturas de vibração de turbomáquinas, através da utilização de três tipos de topologia:

- 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, conforme (Mobley, 1990 e Barron, 1996).

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). Geralmente, as turbomáquinas operam em uma faixa constante de rotação.

Existem diversas formas 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, descritos em (Dron, 1998 e Pusey, 1999). 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, conforme Edwards (1998). 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 (padrão) de um 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 (5), mancal ou suporte frouxos(6), acoplamento(7), *whirl* por atrito(8) e *whirl* por óleo(9), fundação(10), rotor(11) e selagem(12). 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	0	0,2	0	0,5	0,2	0,1	0,9	0,1
11	0,4	0,4	0,1	0	0	0,1	0,9	0,1
12	0,13	0,13	0,14	0,3	0,15	0,15	0,7	0,3

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 Fig. (1) podemos notar que a inserção de um ruído aleatório gera variações em torno do vetor-padrão até 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, o ruído obedece ao critério de variação do vetor-padrão em todas as suas componentes, considerando o peso de cada componente, conforme Adejoro (2004).




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 600 exemplos, sendo 50 exemplos para cada defeito. Para o conjunto de teste foram gerados 360 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 30 exemplos para cada padrão de defeito, de acordo com Adejoro (2004).

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 Eq. (1) indicada a seguir:

$$E = \sum_{i=1}^{360} \sqrt{\frac{1}{12} \sum_{j=1}^{12} (Desejada_{ij} - Rede_{ij})^2} \quad (1)$$

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 ;

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: 15 x 15 neurônios intermediários e 12 neurônios na saída.

No caso da rede *fuzzy*-MLP, para cada componente do vetor de entrada (por exemplo 1xRF), foram criadas 5 funções de pertinência, de formato triangular, representando cinco conjuntos lingüísticos possíveis ("MuitoAlta", "Alta", "Média", "Baixa", "MuitoBaixa"). Com isso, o número de entradas da rede passa de 8 para 40 (5x8). Esse procedimento processa a informação de modo a reduzir a importância das pequenas variações para o classificador. Após uma série de avaliações, a configuração escolhida para o classificador *fuzzy*-MLP, com oito parâmetros de entrada, foi a seguinte: 50 x 50 neurônios intermediários e 12 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: 20 x 20 x 20 neurônios.

5. RESULTADOS

Os resultados estão apresentados sob forma gráfica, tendo sido utilizados 30 vetores de avaliação 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 fossem perfeitamente classificados, os 30 círculos seriam 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.

5.1 Rede MLP

Na Figura (2) estão apresentados os resultados iniciais obtidos para a rede MLP, com topologia 8x15x15x12. Podemos observar, neste gráfico, que a rede não conseguiu uma separação adequada para as classes "desalinhamento angular" e "desalinhamento paralelo", no total de 6 classificações erradas em um total de 180 dados de entrada do conjunto de avaliação (erro=3.4%).




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

5.2 Rede *fuzzy*-MLP

Na Figura (3) estão apresentados os resultados para a rede *fuzzy*-MLP, com topologia 40x50x50x12. Comparando-se estes resultados de classificação com o da rede MLP, observamos que não houve 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 sempre uma classificação do tipo sim ou não. A *fuzzificação* dos dados de entrada permitiu a ocorrência de erro zero.



Figura 3. Rede *fuzzy*-MLP /resultado final /conjunto de avaliação

5.3 Rede SOM

Através do gráfico da Fig. (4) podemos constatar que a rede SOM, da mesma forma que a rede MLP, também não 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. Conforme podemos observar, 5 exemplos foram classificados de forma errada.




Figura 4. Rede SOM /resultado final /conjunto de avaliação

6. CONCLUSÕES

Este trabalho tem por objetivo aplicar técnicas de redes neurais ao diagnóstico de falhas mecânicas de turbomáquinas. A capacidade de cada tipo de rede neural classificar os defeitos foi demonstrada, através da sua capacidade de aprendizado e do seu comportamento em diversas situações de classificação. Foram abordados três tipos de classificadores: 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 aleatórias de valores típicos para os diversos defeitos estudados, esta metodologia não está em desacordo com o aspecto demonstrativo do presente trabalho.

7. AGRADECIMENTOS

Ao CTPETRO/FINEP, pelo apoio ao projeto “Supervisão Inteligente On-line da Condição de Grandes Máquinas de Sistemas Offshore e Refinarias – SUPCON” e à ANP/PRH35 pelo suporte à formação de recursos humanos.

8. REFERÊNCIAS

Adejoro, S. T., 2004, “Avaliação da Condição de Turbomáquinas de Plataformas e Refinarias de Petróleo por Inteligência Artificial”, tese de mestrado. COPPE/UFRJ, Rio de Janeiro, Brasil.

- Barron, D. R., 1996, "Engineering Condition Monitoring: Practice, Methods and Applications", Addison Wesley Longman, New York, USA.
- Cox, C., Emmanouilidis, C. and Macintyre, J., 1998, "An Integrated, Soft Computing Approach for Machine Condition Diagnosis", Proceedings EUFIT, Aachen, Germany, pp.145-150.
- Dron, J. P., Rasolofondraibe, L., Couet, C. e Pavan, A. , 1998, "Fault Detection and Monitoring of a Ball Bearing Benchtest and A Production Machine via Autoregressive Spectrum Analysis", Journal of Sound and Vibration, Vol. 218, no. 3, pp. 501-525.
- Edwards, S., Lees, A. W. e Friswell, M. I., 1998, "Fault Diagnosis of Rotating Machinery", Shock and Vibration Digest, Vol. 30, no. 1, pp 4-13.
- Haykin, S., 1998, "Neural Networks", 2nd edition, Macmillan College Publishing Co., USA.
- He, J. Z., Zhou, Z. H. e CHEN, S. F., 2001, "A general design technique for fault diagnostic systems", Proceedings INNS-IEEE International Joint Conference on Neural Networks II, Tokyo, Japan, pp.1307-1311.
- Hoffman, A. J., Van De Menwe, N. T., Heyns, P. S., Shheffer, C. e Stander, C., 2001, "The Application of Neural Networks to Vibrational Diagnostics for Multiple Fault Conditions", Proceedings COMADEM, Manchester, UK, pp. 128~133.
- McLauchlan, R. e Palleria, S., 2001, "Detection of Defects in Equipments from Vibration Signatures Using Neural Networks", Proceedings ANNIE 2001, St. Louis, USA, pp. 145~152.
- Mitchel, J. S., 1993, "Turbomachinery Analysis and Monitoring", PennWell Books, USA.
- Mobley, R. K., 1990, "An Introduction to Predictive Maintenance", Van Nostrand Reinhold Inc., New York, USA
- Parikh, C. R., Pont, M. J., Li, Y. e Jones, N. B., 1999, "Neural Networks for Condition Monitoring and Fault Diagnosis: the Effect of Training Data on Classifier Performance", Proceedings Condition Monitoring'99, Swansea, UK, pp. 68~74.
- Pusey, H. C., 1999, "Turbomachinery Condition Monitoring and Failure Prognosis Tecnology", Journal of Sound and Vibration, Vol. 219, no. 2, pp 28-33.
- Rezende, J. C. F., 1991, "Manutenção Preditiva em Turbomáquinas utilizando Sistemas Especialistas na Análise de Vibração", Tese Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.
- Sohn, H. e Farrar, C. R., 2000, "A Statistical Pattern Recognition Paradigm for Vibration-Based Structural Health Monitoring", Proceedings ANNIE 2000, Vol.2, St. Louis, USA, pp. 341-348.
- Uhrig, R. E., 1993, "Hybrid Neural Network - Fuzzy Logic Diagnosis System for Vibration Monitoring", Proceedings ANNIE, St. Lois, USA, pp.467-472.
- Balazinski, M., Czogala, E., Jemielniak, K. e Leski, J., 2002 , "Tool condition monitoring using artificial intelligence methods", Engineering Applications of Artificial Intelligence, Vol. 15, no. 1, pp 73-80.

9. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material incluído no seu trabalho.

VIBRATION SIGNATURE AND NEURAL NETWORKS APPLIED TO TURBOMACHINERY FAULTS IDENTIFICATION

Tiago Alberto Piedras Lopes

COPPE/UFRJ Centro de Tecnologia Rio de Janeiro RJ
tiago@peno.coppe.ufrj.br

Antonio Carlos Ramos Troyman

COPPE/UFRJ Centro de Tecnologia Rio de Janeiro RJ
troy@peno.coppe.ufrj.br

Samuel Taiwo Adejoro

COPPE/UFRJ Centro de Tecnologia Rio de Janeiro RJ

samuel@peno.coppe.ufrj.br

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 or machinery 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. The results showed that the fuzzy-MLP neural network is the best solution.*

Keywords - *predictive maintenance, vibration, turbomachinery, neural networks*