

NEURALNET-CBM: FERRAMENTA DE APOIO À MANUTENÇÃO DE MÁQUINAS ROTATIVAS BASEADA EM REDES NEURAIS ARTIFICIAIS

Luis Fernando de Almeida, luis.almeida@unitau.br^{1,2}
Mauro Hugo Mathias, mathias@feg.unesp.br²

¹Universidade de Taubaté, Departamento de Informática, Av. Marechal Deodoro, 605, 12080-000, Taubaté-SP, Brasil

²UNESP - Univ Estadual Paulista, Campus de Guaratinguetá, Departamento de Mecânica, Av. Dr. Ariberto Pereira da Cunha, 333, 12516-410 – Guaratinguetá-SP, Brasil

Resumo: Este artigo apresenta uma ferramenta, chamada NeuralNet-CBM, para auxílio no diagnóstico de falhas em rolamentos, baseada em Redes Neurais Artificiais. Ela utiliza uma MLP cuja entrada são as características do domínio do tempo calculadas a partir de sinais de vibração de rolamentos. A rede foi treinada e testada com um conjunto de dados obtidos a partir de experimentos anteriores desenvolvidos no laboratório da FEG e no EECS laboratories. Os resultados demonstram a eficiência do sistema no diagnóstico da condição de máquina para os diversos dados utilizados se apresentando como uma interessante ferramenta no auxílio na detecção e diagnóstico em certos elementos de máquinas..

Palavras-chave: Redes Neurais Artificiais; Rolamentos; Manutenção Baseada em Condição; Domínio do Tempo

1. INTRODUÇÃO

Segundo Mobley (2002) os custos de manutenção representam a maior parte das operações da empresa em geral. Paradas de produção podem ser causadas pela falha de alguns componentes de máquinas críticas, tais como rolamentos e engrenagens. Rolamentos podem ser classificados como um dos componentes importantes em máquinas rotativas e são responsáveis pela maioria das falhas de máquinas rotativas (Li e Wu, 1989). Alguns problemas encontrados em um rolamento são: fadiga, o desgaste e a falta de lubrificação.

Algumas pesquisas (Takeyasu e Higuchi, 2004; Jardine et al, 2006) apontam o monitoramento baseado na condição (*Condition-Based Monitoring* - CBM) como uma das ferramentas mais importantes que as empresas podem aplicar, a fim de evitar uma série de inconvenientes, ocasionando perda de produção. Em um sistema CBM diagnóstico e prognóstico são dois aspectos importantes. O primeiro trata da detecção de falhas, isolamento e identificação sempre que ele ocorre. O segundo trata de previsão de falha antes que ela ocorra.

A análise de vibração e análise de óleo são duas das principais técnicas para o acompanhamento do estado da máquina (Mathew e Stecki, 1986; Troyer, 1999). Consequentemente, métodos capazes de detectar e prever uma falha se tornaram-se um importante objeto de estudo. Além disso, os métodos baseados em técnicas de Inteligência Artificial têm sido muito populares nas abordagens CBM (Samanta e Al-Balushi, 2003; Yang e Kim, 2006; Rafieea et al, 2007).

Neste sentido, este trabalho apresenta um sistema de CBM baseado em Redes Neurais Artificiais chamado NeuroNet_CBM composto por dois módulos: a vibração e o desgaste de partículas. Nas seções seguintes serão introduzidos conceitos sobre Redes Neurais Artificiais e análise de partículas e análise de vibrações, a arquitetura do NeuralNet_CBM e alguns resultados de testes realizados.

2. REDES NEURAIS ARTIFICIAIS

Segundo Fausett (1994) uma Rede Neural Artificial (RNA) é um sistema de processamento de informação que tem as características de desempenho semelhante a uma rede neural biológica (Fig. 1). RNAs foram desenvolvidas como a generalização da cognição humana e são baseadas nos seguintes pressupostos:

- o processamento de informações é executado pelos neurônios;
- os neurônios estão distribuídos em camadas;
- neurônios em duas camadas são ligadas umas às outras por pesos (sinapses);
- existem três tipos de camadas: entrada (*input layer*), escondida (*hidden layer*) e de saída (*output layer*).




Figura 1. Arquitetura básica de uma RNA.

O tipo mais simples de RNA, chamado Perceptron (Rosenblatt, 1958), apresenta apenas duas camadas - entrada e saída, e pode resolver somente problemas linearmente separáveis. Por outro lado, os problemas mais complexos são tratados utilizando RNAs com camadas escondidas, conhecido como *Multi-Layer Perceptron* (MLP).

O elemento base de uma RNA é o neurônio, composto de: sinais de entrada (*inputs* - x_j); pesos (*weights* - w_{kj}), o nível de ativação (Σ) e função limiar (f). A estrutura básica de um neurônio artificial é ilustrada na Fig. 2.




Figura 2. Estrutura padrão de um neurônio.

Um dos aspectos mais importantes da Inteligência Artificial é a capacidade de aprender uma solução de um determinado problema. Para uma RNA, a aprendizagem é obtida por meio de treinamento, por exemplo, a busca da melhor seleção de pesos sinápticos. O treinamento de uma RNA pode ser realizado utilizando os tipos de aprendizagem básicos: supervisionado ou não supervisionado.

3. ABORDAGENS PREDITIVAS

3.1. Parâmetros estatísticos aplicado a análise de vibrações

Alguns pesquisadores afirmam que as características estatísticas são importantes para a detecção de falhas e no monitoramento e previsão de condição de máquinas (Papoulis, 1991; Nikias e Mendel, 1993; Nandi, 1999). Chen (2000) destaca que a forma, o afastamento e os fatores de impulso são bons indicadores para a falha por fadiga.

A extração de características no domínio do tempo pode ser realizada utilizando parâmetros estatísticos que fornecem informações sobre a distribuição de probabilidade dos dados. A análise desta distribuição pode proporcionar informações sobre a detecção e isolamento de uma falha.

Considerando um segmento de comprimento n , composto pelos pontos x_1, \dots, x_n , a análise no domínio do tempo pode ser realizada por meio das seguintes características: a média (μ), variância (σ^2), curtose, *root mean square* (rms), momentos de ordem superior (m^k), fator de forma (shf), o fator de folga (clf), fator de impulso (imf), fator de crista (crf), o valor de pico (pv), pico-a-valor de pico (ppv), descritos nas eqs. 1 a 10.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)^2 \quad (2)$$

$$m^k = \frac{(1/N-1) \sum_{i=1}^N (\bar{x}_i - \mu)^k}{\sigma^k} \quad (3)$$

$$rms = \sqrt{\frac{\sum_{i=1}^N \bar{x}_i^2}{N}} \quad (4)$$

$$pv = \max(\bar{x}_1, \dots, \bar{x}_n) \quad (5)$$

$$ppv = \max(\bar{x}_1, \dots, \bar{x}_n) - \min(\bar{x}_1, \dots, \bar{x}_n) \quad (6)$$

$$cf = \frac{pv}{rms} \quad (7)$$

$$imf = \frac{pv / \sum_{i=1}^N |\bar{x}_i|}{N} \quad (8)$$

$$shf = \frac{rms}{N} \quad (9)$$

$$clf = \frac{pv}{\frac{\sqrt{\sum_{i=1}^n \bar{x}_i^2}}{n}} \quad (10)$$

Estas características são calculadas para um dado sinal, e o próximo passo consiste em interpretar estes valores para determinar o estado atual da máquina e fornecer informações de caráter preditivas ou prognósticas.

3.2. Análise de Partículas de Desgaste

No monitoramento de condição de máquina, também é possível detectar e prever falhas por meio de análise de partículas de desgaste. O termo partículas de desgaste está associado com o campo da Tribologia em que o desgaste, o atrito e a lubrificação são estudados (Jost, 1990). Os tipos mais comuns de partículas de desgaste microscópicas são: fricção (*rubbing* - R), corte (*cutting* - C), deslizamento severo (*severe sliding* - SS) e fadiga (*fatigue* - F).

As características das partículas podem ser classificadas em termos do seu tamanho, quantidade, morfologia e composição. A partir destas quatro características, tribologistas podem saber a quantidade e o tipo de partículas de desgaste, a gravidade do processo de desgaste, e a taxa em que o desgaste está progredindo. Por exemplo, a composição das partículas de desgaste indica a fonte de desgaste, a morfologia indica a fonte, tipo e taxa de geração, e da mesma dimensão das partículas dá a taxa, o tipo e a gravidade (Laghari, 2003).

Partículas podem ser classificadas em termos de seus atributos composicionais e morfológicos. Os atributos de composição classificam as partículas em metálicas e não metálicas. No caso das partículas metálicas, elas podem ser divididas em: ferrosos (magnética) ou de metais não-ferrosos.

A análise morfológica é um processo *off-line* realizado utilizando-se um microscópio. Especialistas no domínio descrevem uma partícula em termos de seis atributos morfológicos: tamanho, forma, detalhe de borda, cor, espessura e textura (Laghari, 2003). A análise produz informações específicas sobre a condição da superfície dos elementos da máquina a partir da qual as partículas de desgaste são produzidas, o mecanismo de sua formação, e o tipo de desgaste.

4. NEURALNET-CBM

O NeuralNet-CBM consiste em um sistema que utiliza uma MLP para a classificação das falhas de rolamentos e identificação de partículas de desgaste. Para isso, ele é dividido em dois módulos específicos: *Vibration Module* e *Wear Particle Module*. Sua janela principal é mostrada na Fig. 3.



Figura 3. Janela principal do protótipo NeuralNet-CBM.

Ambos os módulos utilizam uma MLP com apenas uma camada oculta com base na hipótese de que essa configuração é suficiente para a classificação com um grau razoável de precisão, na maioria dos casos (Fausset, 1994). Os dados de entrada são normalizados de acordo com a eq. 12, onde L_{\min} representa limite mínimo do intervalo normalizado, L_{\max} o limite máximo deste intervalo, e x_{\max} e x_{\min} representam o maior e o menor x não-normalizado, respectivamente.

$$x_{norm} = L_{\min} + \frac{(L_{\max} - L_{\min}) * (x - x_{\min})}{x_{\max} - x_{\min}} \quad (12)$$

A fim de acelerar o processo de aprendizagem, os pesos para a camada de saída foram inicializados com valores entre -0,5 e 0,5 (Nguyen e Widrow, 1990). Eles sugerem uma inicialização do peso da camada oculta da seguinte forma:

- Aplicar uma iniciação aleatória entre -0,5 e 0,5 para os pesos v_{ij} .
- Calcular o fator de escala β pela Eq. 13, onde p é o número de neurônios da camada oculta e n é o número de neurônios da camada de saída.

$$\beta = 0.7^n \sqrt{p} \quad (13)$$

- Recalcular v_{ij} utilizando a Eq. 14 e a Eq. 15.

$$\|v_j\| = \sqrt{v_{1j}^2 + \dots + v_{nj}^2} \quad (14)$$

$$v_{ij} = \frac{\beta v_{ij}}{\|v_j\|} \quad (15)$$

- Ajuste os pesos do *bias* entre β e $-\beta$.

4.1 *Vibration Module*

Este módulo possui uma arquitetura semelhante, como mostrado na Fig. 4. Ele utiliza dois tipos de MLP: Basic-MLP, para indicar a presença ou ausência de falha; Complete-MLP, para identificar o tipo de falha. A classificação é realizada com base na análise no domínio do tempo considerando os seguintes parâmetros: RMS, curtose, *skewness*,

variância, curtose, momentos de ordem superior, fator de folga, fator de crista, fator de impulso, valor de pico e valor pico-a-pico.




Figura 4. Arquitetura do *Vibration Module*.

O procedimento completo para aplicação deste módulo consiste nos seguintes passos:

- Treinamento da RNA:
 - Importar os dados originais para o formato NeuralNet.
 - Separar estes dados em dados de treinamento e dados de teste.
 - Especificar o número de segmentos e o tamanho de cada segmento para cada conjunto de dados.
 - Calcular as características para cada segmento.
 - Configurar e treinar as redes Basic-MLP e Complete-MLP.
- Aplicação do classificador:
 - Importar os dados originais para o formato NeuralNet.
 - Especificar o número de segmentos.
 - Aplicar a rede Basic-MLP.
 - Se o resultado for igual a 0 exibir a mensagem “sem falha”.
 - Caso contrário, aplicar a rede Complete-MLP e retornar o tipo da falha detectada.

4.2 Wear Particle Module

A RNA para a classificação das partículas de desgaste proposto neste módulo, chamado WP-MLP, é baseado em características morfológicas, que incluem a área, largura, altura, circularidade, alongamento, diâmetro de Feret, proporção maior, menor. Neste caso, esses recursos são gerados por um sistema descrito em Gonçalves e Mathias (2007). A arquitetura proposta é apresentada na Fig. 5.




Figure 5. Arquitetura do *Wear Particle Module*.

O procedimento completo para a sua utilização é definida como segue:

- Treinamento do Classificador:
 - Separar os dados em treinamento e teste.
 - Configurar e treinar a rede WP-MLP.
- Utilização do Classificador:
 - Aplicar WP-MLP.
 - Classificar as partículas de desgaste.

5. TESTES E RESULTADOS

Alguns testes foram realizados a fim de demonstrar os módulos acima mencionados. Os dados foram obtidos a partir de três fontes diferentes:

- DATA-FEG: extraído de uma bancada conforme ilustrada na Fig. 6. Ela é composta por um motor WEG de potência de 1/2 cv, um rolamento, dois acelerômetros modelo B&K4371 disposto na posição horizontal e vertical (Zhang et al., 2005) e um condicionador de sinal ENDEVCO 133.
- DATA-EECS: extraído a partir de dados disponibilizados no site www.eecs.case.edu/laboratory/bearing, referente a pesquisas desenvolvidas pelo laboratório da universidade *Case Western Reserve University*.
- DATA-WEAR: características de partículas de desgaste geradas a partir do trabalho de Gonçalves e Mathias (2007).



Figure 6. Bancada desenvolvida no laboratório da FEG.

5.1 Resultados do *Vibration Module*

A Tab. 1 apresenta a taxa de precisão obtida para as RNA referentes ao *Vibration Module*, considerando um rede com cinco neurônios na camada de entrada (médio, rms, variância, curtose, fator de forma e RMS) e oito neurônios na camada oculta.

Tabela 1: Resultado do treinamento da MLP para *Vibration Module*

Base de Dados	Precisão (%)	
	Basic-MLP	Complete-MLP
DATA-EECS	99,4	94,7
DATA-FEG	99,0	93,1

A base de dados DATA-FEG é composta de amostras extraídas de cinco condições de rolamento (rolamento sem defeito, pista interna defeito suave, pista interna com defeito grave, pista externa com defeito suave e pista externa com defeito grave) e os dados DATA-EECS é composto de quatro condições (rolamento normal, defeito na pista interna, defeito na pista externa e defeito no elemento de rolamento).

A Fig. 7 ilustra um exemplo de classificação, produzido pelo NeuraNet-CBM usando DATA-EECS, apresentando resultados com e sem falhas. No caso de uma falha detectada, o sistema executa o classificador Neural_Net para indicar o tipo de falha, tal como apresentado na Fig. 8.




Figura 7. Classificação básica: (a) sem defeito; (b) falha detectada.




Figure 8. Classificação do defeito.

5.2 Resultados do Wear Particle Module

Para este módulo, foi utilizado um conjunto de dados chamado DATA-WEAR construído com os registros relacionados a quatro tipos de partículas microscópicas de desgaste: R, C, SS e F. Portanto, um conjunto de testes variando o número de neurônios na camada oculta, de 3 a 15, foi realizado a fim de definir a arquitetura de rede apropriada. O conteúdo da base de dados foi dividido em dois grupos: treinamento e teste. Ambos são representados por uma matriz $P \times F$, onde P representa o total de partículas de formação e F representa o número de atributos utilizados.

Em resumo, a MLP final utilizada apresenta 5 neurônios na camada de entrada, 10 na camada oculta e 4 na camada de saída. A Tab. 2 apresenta os resultados das melhores configurações. Os testes foram realizados para determinar o melhor conjunto de atributos para o MLP a ser utilizado pelo classificador. Por esse motivo, todas as combinações possíveis entre estas características foram levadas em consideração.

Tabela 2: Resultado de treinamento da MLP para Wear Particle Module

FEATURES (input layer)					RC(%)
area	height	minor	elongation	aspect ratio	96.0
area	height	minor	circularity	elongation	95.2
area	minor	circularity	elongation	aspect ratio	95.2
area	height	circularity	elongation	aspect ratio	95.2
area	height	minor	circularity	aspect ratio	94.1

A partir da melhor configuração apresentada na Tab. 1, executou-se um teste para determinar o desempenho do sistema em termos do número de épocas, ou seja, o tempo de aprendizagem, variando de 100 a 2000. Os resultados finais são apresentados na Fig. 9 que mostra a estabilidade no treinamento a partir de 1000 épocas.




Figura 9: Janela para teste de desempenho.

6. CONCLUSÃO

Este trabalho apresentou um protótipo de apoio CBM nomeado Neural_Net que é capaz de ajudar no diagnóstico e detecção de falhas em elementos de máquinas determinadas. Dois tipos de análise são possíveis na versão atual: vibração e análise de partículas de desgaste com base em atributos morfológicos. O sistema proposto foi aplicado a vários conjuntos de dados e foi mostrado para ser útil.

Além disso, existem muitos aspectos positivos do sistema Neural_Net propostas, tais como: a flexibilidade em aceitar diferentes arquiteturas MLP, adaptação a outros conjuntos de dados, interação com os módulos de análise e apresentação dos resultados através de uma interface gráfica amigável, dentre outros.

Versões futuras podem incluir novas abordagens para a extração de recursos no *Vibration Module* (análise no domínio da frequência e *wavelets*, por exemplo); a análise de outros aspectos para partículas de desgaste, como, textura, composição; classificadores baseados em prognósticos; aplicação de redes do tipo Kohonen; aplicação de outras abordagens de Inteligência Artificial (Redes Bayesianas, Raciocínio Baseado em Casos).

Por fim, temos também a intenção de implementar uma versão baseada na plataforma *freeware*, como a linguagem Java. A versão atual foi implementada em *Borland Builder C++ 6.0*, funcionando apenas no sistema operacional Windows.

7. AGRADECIMENTOS

Os autores gostariam de agradecer à Universidade Estadual Paulista (UNESP) e à Universidade de Taubaté (UNITAU) pelo apoio recebido para o desenvolvimento das pesquisas aqui descritas.

8. REFERÊNCIAS

- Chen, P. 2000. Bearing condition monitoring and fault diagnosis. Master of Science Thesis, Department of Mechanical and Manufacturing Engineering, University of Calgary.
- Fausett, L.V. 1994, "Fundamentals of neural networks – architectures, algorithms and applications". Addison Wesley.
- Gonçalves V. D., Mathias M.H. 2007, "A mechatronic system applied to wear particle analysis", Slovenian Society for Tribology, ECOTRIB, Slovenia, v.2, pp 1065-1072.
- Jardine, A. K. S.; Lin, D.; Banjevic, D. 2006, "A review on machinery diagnostics and prognostics implementing condition-based maintenance". *Mechanical Systems and Signal Processing*, v. 20, pp. 1483–1510.
- Jost, H. P. (1990). *Tribology - origin and future*. *Wear*, v. 136, pp. 1-17.
- Li, C. J., Wu, S. M. 1989, "On-line detection of localized defects in bearings by pattern recognition analysis". *Journal of Engineering for Industry*, v. 111, pp. 331-336.
- Laghari, M. S. 2003, Recognition of texture types of wear particles. *Neural Comput & Application*, v. 12, pp. 18-25.
- Mathew, J.; Stecki, J. 1986, "Comparison of vibration and direct reading ferrographic techniques in application to high speed gears operating under steady-state conditions", *J. Soc. Tribol. Lubricat. Eng.*, pp. 646.
- Mobley, R. K. 2002, "An introduction to predictive maintenance". 2 ed., Elsevier Science.
- Nandi, A. K. 1999, "Blind estimation using high-orders statistics". Kluwer Academic Publishers, Boston.
- Nguyen, D.; Widrow, B. 1990. Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. *Proceedings of the International Joint Conference on Neural Networks*, v. 3, pp. 21-26,

- Nikias, C. L.; Mendel, J. M. 1993, "Signal processing with higher order spectra", IEEE Signal Processing, v. 10, n. 4, pp. 10-37.
- Papoulis, A. 1991, "Probability, random variables and stochastic processes". McGrawHill Inc., New York.
- Rafieea, J.; Arvania, F.; Harifib, A.; Sadeghi, M. H. 2007, "Intelligent condition monitoring of a gearbox using artificial neural network". Mechanical Systems and Signal Processing, v. 21, pp. 1746-1754.
- Rosenblatt, F. 1958, "The perceptron, a probabilistic model for information storage and organization in the brain", Psychol. Rev., n. 65, pp. 386-408.
- Samanta, B.; Al-Balushi, K. R. 2003, "Artificial neural network based fault diagnostics of rolling element bearings using time-domain features". Mechanical Systems and Signal Processing, v. 17, n. 2, pp. 317-328.
- Takeyasu, K.; Higuchi, Y.. 2004, "Analysis of the behavior of kurtosis by simplified model and its application to machine diagnosis". In Proceedings of the Fifth Asia Pacific Industrial Engineering and Management Systems.
- Troyer, D. D. 1999, "Effective Integration of Vibration Analysis and Oil Analysis", In Proceedings of the conference of Condition Monitoring, pp. 411-420.
- Yang, B. S., Kim, K. J. 2006, "Application of Dempster-Shafer theory in fault diagnosis of induction motors using vibration and current signals". Mechanical Systems and Signal Processing. v. 20, pp. 403-420.
- Zhang, L., Jack, L.B., Nandi, A.K., 2005, "Fault detection using genetic programming". Mechanical Systems and Signal Processing, v. 19, pp. 271-289.

9. DIREITOS AUTORAIS

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

NEURALNET-CBM: A SUPPORT TOOL FOR ROTATING MACHINE MAINTENANCE BASED ON ARTIFICIAL NEURAL NETWORKS

Luis Fernando de Almeida, luis.almeida@unitau.br^{1,2}
Mauro Hugo Mathias, mathias@feg.unesp.br²

¹University of Taubaté, Department of Informatics, 605, Marechal Deodoro, Av., 12080-000, Taubaté-SP, Brazil

²UNESP - Univ Estadual Paulista, Campus de Guaratinguetá, Departamento de Mecânica, 333, Dr. Ariberto Pereira da Cunha, Av., 12516-410 – Guaratinguetá-SP, Brazil

Abstract. *This paper presents a system based on Artificial Neural Networks for fault diagnosis of rolling element bearings and for wear particle analysis. The system is composed by two modules: vibration and wear particle. The first has used the features of time-domain vibration signals with normal and defective bearings; the later has used morphological attributes of the wear particles. The system proposed, named Neural_Net-CBM, uses Multi-Layer Perceptron networks for identification of various fault types. The MLP was trained and tested with a set of the experimental data obtained from previous experiments developed by FEG and EECS laboratories. The results show the effectiveness of the system in diagnosis of the machine condition for the various data used. The proposed system has been applied to several datasets and has been shown to be useful. The Neural_Net-CBM system applied showed to be able to assist with fault detection and diagnosis in certain machine elements.*

Keywords: *Artificial Neural Networks; Rolling Bearing; Condition Based Maintenance; Time Domain.*