

# **CLASSIFICAÇÃO DE FALHAS EM MÁQUINAS ROTATIVAS USANDO A RESPOSTA TRANSIENTE E TRANSFORMADA DE WAVELET PACKET**

**Darley Fiárcio de Arruda Santiago**

CEFET / PI - Centro Federal de Educação Tecnológica do Piauí / UNED-Floriano

UNICAMP - Faculdade de Engenharia Mecânica - Departamento de Projeto Mecânico

Rua Francisco Urquiza Machado, 462, Floriano, PI., CEP: 64800-000 - darley@cefetpi.br

**Robson Pederiva**

UNICAMP - Faculdade de Engenharia Mecânica - Departamento de Projeto Mecânico

Caixa Postal: 6051 - Campinas, S.P., CEP: 13083-970 - robson@fem.unicamp.br

**Resumo.** O estudo do comportamento dinâmico e o diagnóstico de falhas de máquinas rotativas durante a partida, parada e passagem pelas velocidades críticas têm se tornado muito importante, principalmente em máquinas que são ligadas e desligadas freqüentemente e que giram com altas velocidades. Logo, o monitoramento das vibrações durante o regime transiente, pode revelar informações relacionadas a uma falha de natureza não-estacionária que dificilmente seria diagnosticado no regime estacionário. Neste estudo a decomposição de um sinal através da Transformada de Wavelet Packet (WPT) é usada como uma técnica alternativa de extração e compactação de parâmetros em bandas de freqüência independentes. A fórmula da entropia de Shannon é utilizada para quantificar a energia contida no sinal transiente em cada banda de freqüência da wavelet packet, já que a presença de falhas na máquina indica níveis significativos de energia relacionados às freqüências do defeito. Do ponto de vista prático, a utilização de sinais, tanto no domínio do tempo como no da freqüência, obtidos durante o regime estacionário não são muito adequados para utilização como dados de entrada de redes neurais. Por isso, consideram-se neste trabalho os níveis de energia quantificados em cada banda de freqüência do sinal transiente através da wavelet packet como parâmetros de entrada das redes neurais. Uma das vantagens de se utilizar estes parâmetros como entradas diz respeito a maior compactação dos dados. Diante dos resultados obtidos, verifica-se que a utilização da WPT em conjunção com redes neurais são técnicas bastante efetivas para o diagnóstico e classificação de falhas introduzidas numa bancada experimental de testes.

**Palavras-chave:** Máquinas Rotativas, Resposta Transiente, Wavelet Packet, Redes Neurais.

## **1. INTRODUÇÃO**

Muitos programas de manutenção preditiva e sistemas de diagnóstico de falhas utilizam a condição da máquina para identificar e classificar falhas através da análise de vibrações (Zhang *et al.*, 1996). A análise de vibrações tem sido largamente usada no diagnóstico de falhas e monitoramento da condição de máquinas rotativas e é feita, em geral, no domínio do tempo ou no domínio da freqüência.

Os métodos no domínio do tempo são geralmente mais sensíveis à falhas de natureza transitória. Características contidas nos sinais com defeitos que estão sendo monitorados podem ser extraídas por esses métodos. Dentre os principais métodos no domínio do tempo, pode-se citar, valor de

R.M.S., valor de pico, fator de crista, kurtosis. Estes parâmetros, uma vez caracterizados, freqüentemente fornecem diagnósticos satisfatórios. Contudo, se estas falhas têm comportamento complexo, por exemplo, não-estacionário ou transiente, estes métodos no domínio no tempo não são confiáveis o suficiente para diagnosticá-las.

Os métodos no domínio da freqüência e que normalmente são utilizados no monitoramento de máquinas rotativas incluem Análise Espectral, Análise Cepstral e Análise de Envelope. Para sinais estacionários, a análise espectral ou transformada de Fourier (FT) é extremamente útil. Entretanto, ela não é muito adequada para a análise de sinais cujo comportamento é de natureza não-estacionária ou transiente.

A resposta transiente obtida durante a partida e parada da máquina é de natureza não-estacionária. Para tratar estes sinais, várias técnicas de análise em tempo-freqüência (Transformada de Gabor, Wigner-Ville, etc.) e tempo-escala (Transformada de Wavelet) foram desenvolvidas. A Transformada de Wavelet (WT) é uma ferramenta efetiva para o processamento de sinais estacionários e não-estacionários. A WT possibilita fornecer informações contidas no sinal simultaneamente no domínio do tempo e freqüência.

As vibrações mecânicas em máquinas rotativas são, principalmente, causadas por desbalanceamento, desalinhamento, folga mecânica, atrito, trincas, etc. A maioria dos estudos publicados na literatura tem dado bastante atenção ao diagnóstico dessas falhas utilizando o sinal estacionário (Wauer, 1990; Xu & Marangoni, 1994; Sekhar & Prabhu, 1995; Hamzaqui *et al.*, 1998; Silva, 1999). Por outro lado, o estudo do comportamento dinâmico de rotores e o diagnóstico de falhas durante o regime transiente, ou seja, durante a partida ('run-up, start-up') e parada ('shutdown, coast-down') da máquina, despertaram o interesse de muitos pesquisadores (Smalley, 1989; Gasch, 1993; Pacheco & Steffen Jr., 1995, Al-Bedoor, 2000; Santiago & Pederiva, 2003).

Neste trabalho utiliza-se a resposta transiente para fins de aplicação da transformada de wavelet visando o diagnóstico de falhas introduzidas numa bancada experimental de testes tais como, desbalanceamento, desalinhamento e folga mecânica. A decomposição de um sinal através da Transformada de Wavelet Packet (WPT) é usada como uma técnica alternativa de extração e compactação de parâmetros em bandas de freqüência independentes. A fórmula da entropia de Shannon é utilizada para quantificar a energia contida no sinal transiente em cada banda de freqüência da wavelet packet, já que a presença de falhas na máquina indica níveis significativos de energia relacionados às freqüências do defeito. Do ponto de vista prático, a utilização de sinais, tanto no domínio do tempo como no da freqüência, obtidos durante o regime estacionário não são muito adequados para utilização como dados de entrada de redes neurais (Lépore *et al.*, 2001; Santiago *et al.*, 2002; Santiago, 2004).

Assim sendo, consideram-se os níveis de energia quantificados em cada banda de freqüência do sinal transiente através da wavelet packet como parâmetros de entrada das redes neurais. Uma das vantagens de se utilizar estes parâmetros como entradas diz respeito a maior compactação dos dados. Diante dos resultados obtidos, verifica-se que a utilização da WPT em conjunção com redes neurais são técnicas bastante efetivas para a classificação de falhas introduzidas numa bancada experimental de testes.

## 2. TRANSFORMADA DE WAVELET

A Transformada Contínua de Wavelet (CWT) de um sinal  $x(t)$  é definida por:

$$CWT(a,b) = \int_{-\infty}^{+\infty} x(t) \cdot \psi_{a,b}^*(t) dt, \quad a \in \mathbb{R}, a \neq 0 \quad (1)$$

onde  $\psi(t)$  é a wavelet mãe,  $\psi^*(t)$  é o conjugado complexo de  $\psi(t)$  e  $\psi_{a,b}(t) = 1/\sqrt{|a|} \psi((t-b)/a)$  são as wavelets filhas. O parâmetro  $a$ , chamado de escala, escalona uma função por compressão ou dilatação; e  $b$  é chamado de coeficiente de translação e

simplesmente avança ou atrasa a posição da wavelet no eixo do tempo. A diferença básica entre a Transformada de Fourier de Curta Direção (STFT) e a CWT é que na CWT usa-se uma escala  $a$  variável, ao invés de uma freqüência  $f$  variável na STFT (Chan, 1996).

No cálculo da CWT o parâmetro escala e posição muda continuamente. Contudo, o cálculo dos coeficientes da wavelet para toda escala possível pode representar um considerável esforço computacional e uma quantidade de dados muito grande para posteriormente serem analisados. Assim sendo, o uso da Transformada Discreta de Wavelet (DWT) torna-se importante, pois ela permite a discretização da wavelet numa escala baseada na potência de dois, ou seja, na escala  $2^j$ , chamada de escala diadica. O uso dessa escala torna a implementação computacional mais rápida e a análise dos dados bastante eficiente. Portanto, os parâmetros  $a$  e  $b$  da expressão (1) são substituídos por  $2^j$  e  $k2^j$ , respectivamente, e a DWT é definida por (Chui, 1992):

$$DWT(j, k) = \int_{-\infty}^{+\infty} x(t) \psi_{j,k}^*(t) dt, \quad j \in \mathbb{Z}, \quad (2)$$

onde,  $\psi_{j,k}(t) = 1/\sqrt{2^j} \psi((t - k2^j)/2^j)$  são funções wavelets ortogonais (Daubechies, 1988).

Semelhante a Transformada Rápida de Fourier (FFT), existe um algoritmo para implementação da DWT baseado na decomposição Rápida da Transformada de Wavelet (FWT), que é normalmente utilizado, e conhecido como Análise de Multiresolução (MRA) ou Algoritmo Piramidal de Mallat, o qual foi desenvolvido por Mallat em 1988 (Misiti *et al*, 1997; Mallat, 1989). Este algoritmo utiliza um processo especial de filtragem para decompor o sinal, onde, o conteúdo do sinal em baixa freqüência é chamado de *aproximação*, e o de alta freqüência é chamado de *detalhe*. Este processo de filtragem decompõe o sinal original em *aproximações* e *detalhes*, e podem ser interpretados como filtros passa-baixa e passa-alta, respectivamente, como mostra a Fig. (1a).

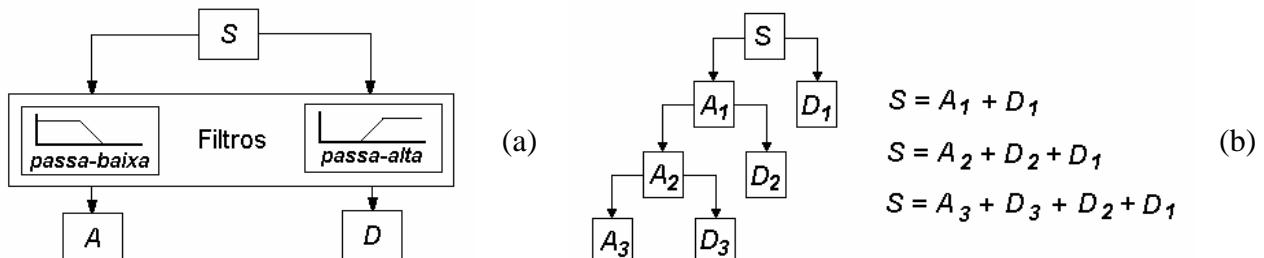


Figura 1. (a) Diagrama esquemático da análise de multiresolução;  
(b) Árvore de decomposição da wavelet em três níveis.

A teoria de multiresolução permite decompor um sinal da seguinte forma: primeiro, um sinal original discreto  $S$  é decomposto no primeiro nível em duas componentes  $A_1$  e  $D_1$  por um filtro passa-baixa e um passa-alta, respectivamente. O  $A_1$ , é chamado de aproximação do sinal e  $D_1$ , é chamado de detalhe do sinal. Para o segundo nível, a aproximação  $A_1$  é agora decomposta em uma nova aproximação,  $A_2$ , e um detalhe  $D_2$ . Este procedimento pode ser repetido para o terceiro nível, quarto, etc. A Figura (1b) mostra a árvore de decomposição da wavelet de um sinal em três níveis.

Por outro lado, a Transformada de Wavelet Packet (WPT) é uma generalização da transformada discreta de wavelet. Enquanto a DWT mostrada na Fig. (2a) decompõe o sinal somente em baixas freqüências, a WPT mostrada na Fig. (2b) decompõe o sinal em baixas e altas freqüências. Cada vetor  $A_j$  possui  $N_t / 2^j$  coeficientes, onde  $N_t$  é o comprimento do sinal  $S$ , e fornece informação a respeito de uma banda de freqüência  $[0, F_s / 2^{j+1}]$ , e  $F_s$  é a freqüência de amostragem do sinal. Cada nó ou packet WPT é indexado por um par de inteiros  $(j, k)$ , onde  $j$  é o nível correspondente

de decomposição e  $k$  é a ordem da posição do nó em um nível específico. Em cada nível  $j$ , existe  $2^j$  nós e sua ordem é  $k = 0, 1, \dots, 2^j - 1$ . Por exemplo, no nível três ( $j = 3$ ), existem 8 nós ou packets. Um vetor de coeficientes da wavelet packet  $c_{j,k}$  corresponde a cada nó  $(j, k)$  e o seu comprimento é aproximadamente  $N_t / 2^j$ .

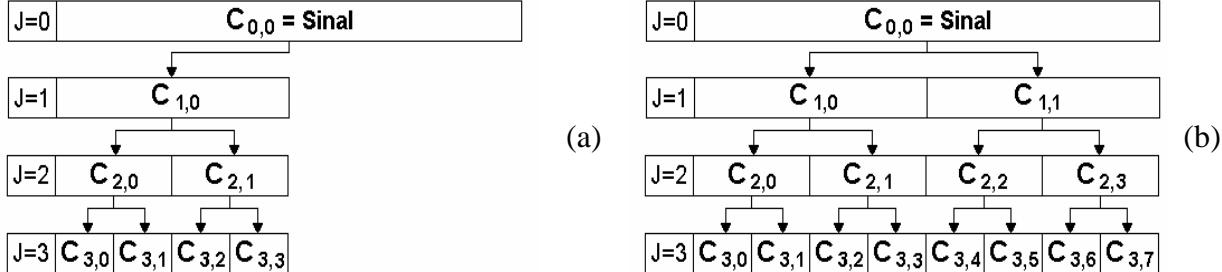


Figura 2. Decomposição do sinal original com, (a) DWT e (b) Wavelet Packet

Observando-se a Fig. (2b), os vetores  $c_{j,k}$  contém informação do sinal original em diferentes bandas de freqüências. Por exemplo, se a freqüência de amostragem do sinal é 16000 Hz, então a banda de freqüência de análise relacionada ao vetor  $c_{0,0}$  é de 0-8000 Hz. Para  $c_{1,0}$  de 0-4000 Hz, para  $c_{1,1}$  de 4000-8000 Hz, para  $c_{3,0}$  de 0-1000 Hz, e assim por diante. Uma vantagem da WPT é que ela permite analisar as informações contidas no sinal, sejam elas estacionárias ou não-estacionárias em diferentes resoluções tempo-freqüência. Outra vantagem da WPT diz respeito à compactação da informação contida no sinal. Por exemplo, para  $j = 3$  e  $N_t = 1024$  amostras, o vetor  $c_{3,0}$  possui  $N_t / 2^j = 128$  amostras e banda de freqüência igual a 0-1000 Hz.

Nota-se que cada packet  $c_{j,k}$  da WPT retém informação do sinal original de forma compacta. Este fato é muito importante na análise e processamento de sinais, principalmente na área de diagnóstico de falhas, pois podemos reter informação do sinal somente naquela banda de freqüência onde as freqüências da falha aparecem. Na prática, normalmente escolhem-se os packets que retém mais informação do sinal original e se descarta os packets que contêm ruído e informações menos importantes. Para isso, utilizam-se alguns critérios de seleção desses packets ótimos. Um critério bastante usado é o critério baseado na quantificação da energia contida no sinal (Scheffer & Heyns, 2001). Neste trabalho, é usada a fórmula da entropia de Shannon para estimar a energia contida no sinal e em cada nó da wavelet packet (Misiti *et al.*, 1997), a qual é dada por:

$$E(s) = -\sum_i s_i^2 \log(s_i)^2 \quad (3)$$

onde,  $s$  é o sinal e  $s_i$  é a amostra do sinal no instante  $i$ .

Portanto, conclui-se que a aplicação da Transformada de Wavelet Packet baseada na quantificação da energia do sinal original em bandas de freqüências específicas permite a extração e a obtenção de informações de forma bastante compacta. Isto pode ser muito importante em tarefas de reconhecimento de padrões com aplicações em redes neurais. Estes aspectos serão investigados neste trabalho.

### 3. APLICAÇÃO EXPERIMENTAL

Normalmente o reconhecimento de falhas requer uma análise detalhada dos sinais das máquinas para identificar padrões de falhas específicos. 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 falhas 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 técnica que possibilita o monitoramento on-line da manutenção preditiva visando à minimização do tempo entre o recebimento das informações e o diagnóstico do problema (Lucifredi *et al.*, 2000; Santiago *et al.*, 2002).

Nesta parte, faz-se uma aplicação da Transformada de Wavelet Packet (WPT) na resposta transiente, a qual foi obtida durante a partida e parada da máquina, com fins de diagnóstico de falhas em máquinas rotativas. As condições de falhas introduzidas na bancada experimental de ensaios, mostrada na Figura 3, foram o desalinhamento angular (dois níveis de desalinhamento, 0,5 mm e 1 mm), folga mecânica. O sinal de partida e parada da condição normal ou sem defeito foi também medido para efeito de comparação com as condições com falhas.

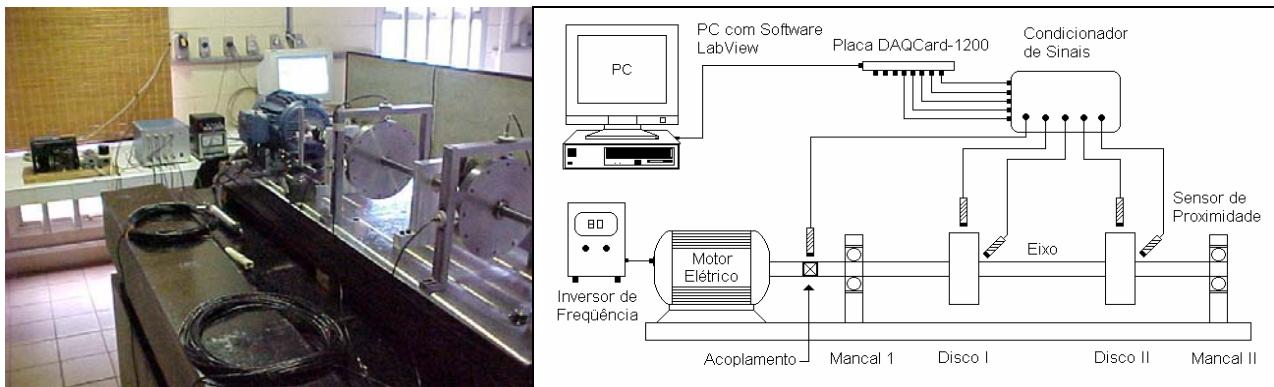


Figura 3. Detalhes da instrumentação utilizada na bancada experimental.

A bancada experimental, a qual representa um sistema dinâmico rotativo, consiste basicamente de um motor elétrico, um acoplamento, um eixo flexível suportando dois discos rígidos e apoiado por dois mancais de rolamentos idênticos. O sistema é acionado por um motor elétrico WEG de corrente alternada, trifásico, 3 CV e rotação nominal de 3465 rpm. O material do eixo é Aço ABNT 1045, cujo diâmetro é de 17 mm. A instrumentação utilizada na aplicação experimental inclui cinco sensores de proximidade do tipo indutivo ou “Eddy-current”, com faixa linear de 0 a 2 mm e sensibilidade de 5 V/mm, para medição dos deslocamentos. O sistema de aquisição de sinais é composto por um PC Pentium II / 300 MHz, equipado com o *Software LabView* e uma placa de aquisição de dados (8 canais) do tipo PCMCIA DAQCard-1200, ambos da *National Instruments*. Na aquisição dos sinais de vibração (deslocamento), durante a partida e parada da máquina, foram usados 12000 pontos de amostragem, freqüência de amostragem de 1000 Hz e rotação variando de 0 a 2400 rpm.

Do ponto de vista prático, a utilização de sinais, tanto no domínio do tempo como no da freqüência, obtidos durante o regime estacionário não são muito adequados como dados de entrada de redes neurais, devido à presença de ruídos e informações redundantes contidos no sinal (Figura 4, Metodologia - 1).

Portanto, apresenta-se neste trabalho, uma aplicação da metodologia de compactação e extração de parâmetros, descrita na seção 2, chamada *Wavelet Packet Neural Network* (WPNN), para fins de classificação de falhas em máquinas rotativas durante o regime transiente. A estrutura da *Wavelet Packet Neural Network* (WPNN), Figura 4 (Metodologia - 3), é fundamentada na teoria de transformada de wavelet em conjunção com redes neurais e funciona como uma técnica alternativa de classificação de padrões de falhas. Neste trabalho, utiliza-se a wavelet do tipo *db10* da família Daubechies *dbN* (Misiti *et al.*, 1997) já disponibilizada no *toolbox de wavelet do Matlab ®*.

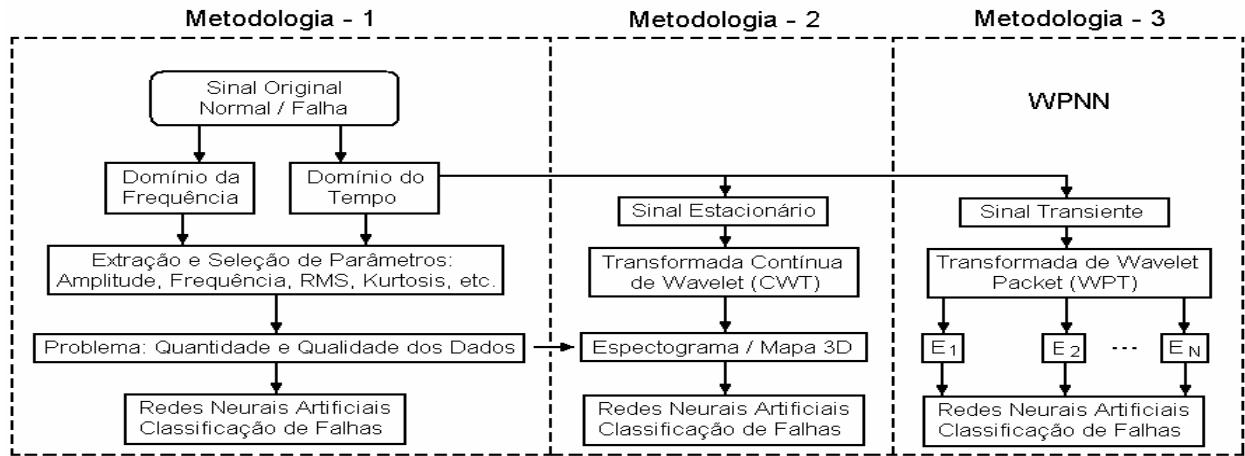


Figura 4. Estrutura da metodologia *Wavelet Packet Neural Network* (WPNN)

Nesta seção, apresentam-se alguns resultados obtidos a partir da implementação e treinamento de diversas arquiteturas de redes neurais do tipo perceptrons de múltiplas camadas (MLP) 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 arquiteturas de 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). As falhas foram introduzidas na bancada de testes separadamente, e, em seguida foram feitas as aquisições dos sinais de vibrações (deslocamento) utilizando um sensor de proximidade e posicionado nas vizinhanças do primeiro disco na direção horizontal.

A seguir, mostram-se na Fig. (5) os sinais de deslocamento (padrões de falhas) obtidos para diferentes condições de falhas introduzidas na bancada de testes (Condição normal, Desalinhamento de 0,5 mm, Desalinhamento de 1 mm e Folga mecânica). Foram feitas 80 aquisições de sinais de vibrações aleatoriamente, sendo 20 aquisições para cada tipo de falha. Os sinais foram adquiridos com 12000 amostras, tempo de aquisição de 12 segundos, freqüência de amostragem de 1000 Hz e rotação variando de 0 a 2400 rpm com aceleração de  $\alpha = 20 \text{ rad} / \text{s}^2$ .

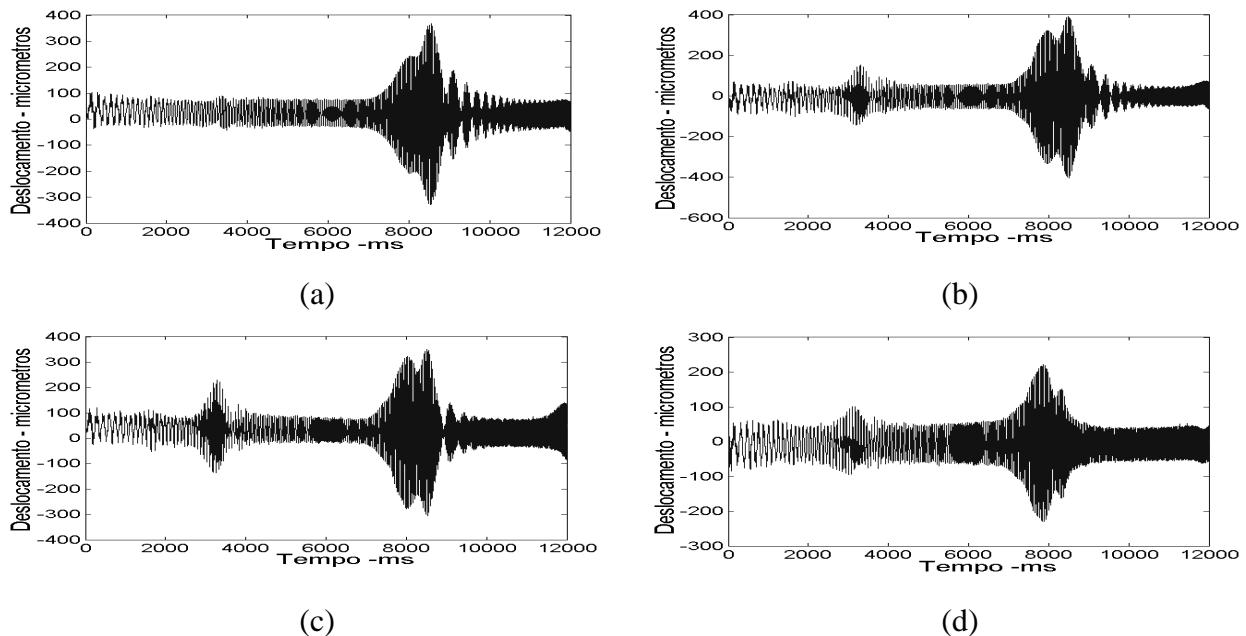


Figura 5. Sinal de partida (padrão); (a) Condição normal, (b) Desalinhamento de 0,5 mm, (c) Desalinhamento de 1 mm e (d) Folga mecânica.

O conjunto de dados reais utilizados para treinamento, teste e validação das arquiteturas de redes neurais implementadas para classificar, por exemplo, as quatro falhas introduzidas na bancada de testes foi dividido da seguinte maneira: 40 sinais de deslocamento (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).

Foram utilizados como parâmetros de treinamento de entrada e saída das redes neurais os seguintes dados: Como parâmetros de entrada foram utilizados os valores de energia contido no sinal e em cada nó da wavelet packet, dados por  $E_1, E_2 \dots E_N$  conforme mostra a Fig. (4). A fórmula da entropia de Shannon, expressão (3), é utilizada para quantificar a energia contida no sinal transiente em cada banda de freqüência da wavelet packet; e como parâmetros de saída atribuíram-se os seguintes valores (níveis de ativação): 1000 (Condição Normal), 0100 (Folga Mecânica), 0010 (Desalinhamento 1 ou de 0,5 mm) e 0001 (Desalinhamento 2 ou de 1 mm).

Alguns aspectos importantes observados neste estudo motivaram ainda mais a aplicação da metodologia WPNN proposta para classificação de falhas em máquinas rotativas, dentre eles podem-se destacar: (1) Tendência de uniformidade dos valores de energia e repetitibilidade dos quatro padrões de falhas, conforme mostra a Fig. (6a) para as dez primeiras aquisições; (2) Diminuição dos valores quantificados da energia simultaneamente em cada packet ou banda de freqüência para três padrões de falhas conforme a aceleração aumenta, como mostram as Figuras (6b), (6c) e (6d).

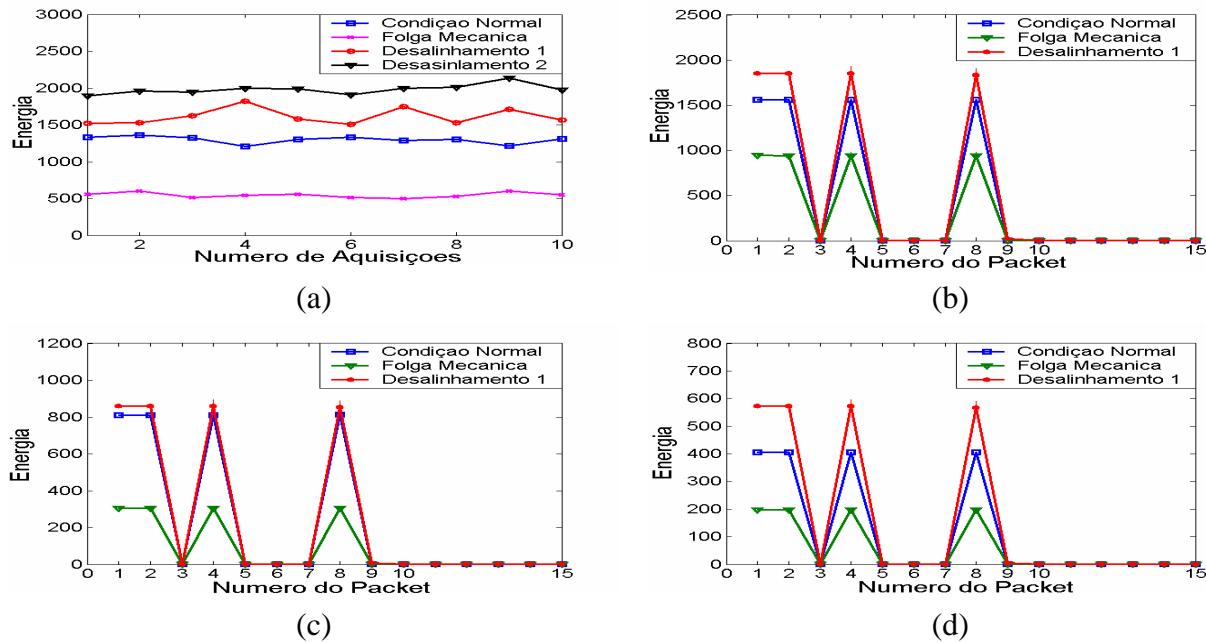


Figura 6. (a) Energia das 10 primeiras aquisições, (b) Energia para  $a = 20 \text{ rad/s}^2$ ,  
(c) Energia para  $a = 38 \text{ rad/s}^2$  e (d) Energia para  $a = 75 \text{ rad/s}^2$ .

O objetivo da aplicação de redes neurais em casos reais é investigar a sua eficiência e viabilidade como ferramenta de classificação de falhas em máquinas rotativas. Utilizaram-se neste trabalho como dados de treinamento 40 (padrões) com quatro falhas diferentes e alimentados na entrada da rede de forma aleatória (Valores de energia  $E_1, E_2 \dots E_N$ , dos sinais de cada falha correspondentes aos 10 primeiros packets, neste caso  $N = 10$ ) e como dados de saída os níveis de ativação correspondentes a cada tipo de falha já citado anteriormente.

Durante as fases de implementação, treinamento, teste e validação da rede neural *multilayer perceptron* (MLP) foram considerados os seguintes parâmetros de treinamento: 1) Camadas de Entrada e Oculta: Função de Ativação Tangente Hiperbólica; 2) Camada de Saída: Função de

Ativação Linear; 3) Método de Otimização: Levemberg-Marquardt; 4) Número de Épocas: 300 Épocas e 5) Erro Total Admissível: 1e-5. A seguir, mostra-se na Tab. (1) um resumo dos resultados obtidos com o treinamento de 5 tipos de arquiteturas de redes neurais.

Tabela 1. Resultados das Taxas de Acerto de Diferentes Arquiteturas de Redes Neurais

Arquitetura da Rede	Número de Épocas	Tempo de Treinamento (s)	Taxa de Acerto (%) Rede de Teste	Taxa de Acerto (%) Rede de Validação
10x5x4	14	10,37	95	95
10x8x4	30	7,44	90	85
10x10x4	10	5,87	100	100
10x5x5x4	18	5,69	100	100
10x8x8x4	29	13,11	100	100

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

1. A rede neural com arquitetura 10x8x4 (10 neurônios na camada de entrada, 8 neurônios na 1ª camada oculta e 4 neurônios na camada de saída) foi quem apresentou menor taxa de acerto dos sinais (padrões) a ela apresentados, ou seja, dos 20 padrões de testes apresentados a rede ela reconheceu 18 ou 90%, e dos 20 padrões de validação apresentados a rede ela reconheceu 17 ou 85% deles; e a que melhor apresentou capacidade de generalização foi a rede 10x10x4;
2. Em geral, observa-se na Tab. (1) que as demais arquiteturas de redes neurais treinadas foram capazes de classificar com eficiência de até 100% as quatro falhas introduzidas na bancada de testes (máquina rotativa);
3. Os resultados obtidos mostram que a *Wavelet Packet Neural Network* pode ser utilizada satisfatoriamente como técnica alternativa de classificação e diagnóstico de falhas introduzidas em máquinas rotativas. A Fig. (7) mostra os resultados obtidos com a rede neural 10x10x4, a qual foi capaz de classificar satisfatoriamente as falhas introduzidas na bancada de testes.

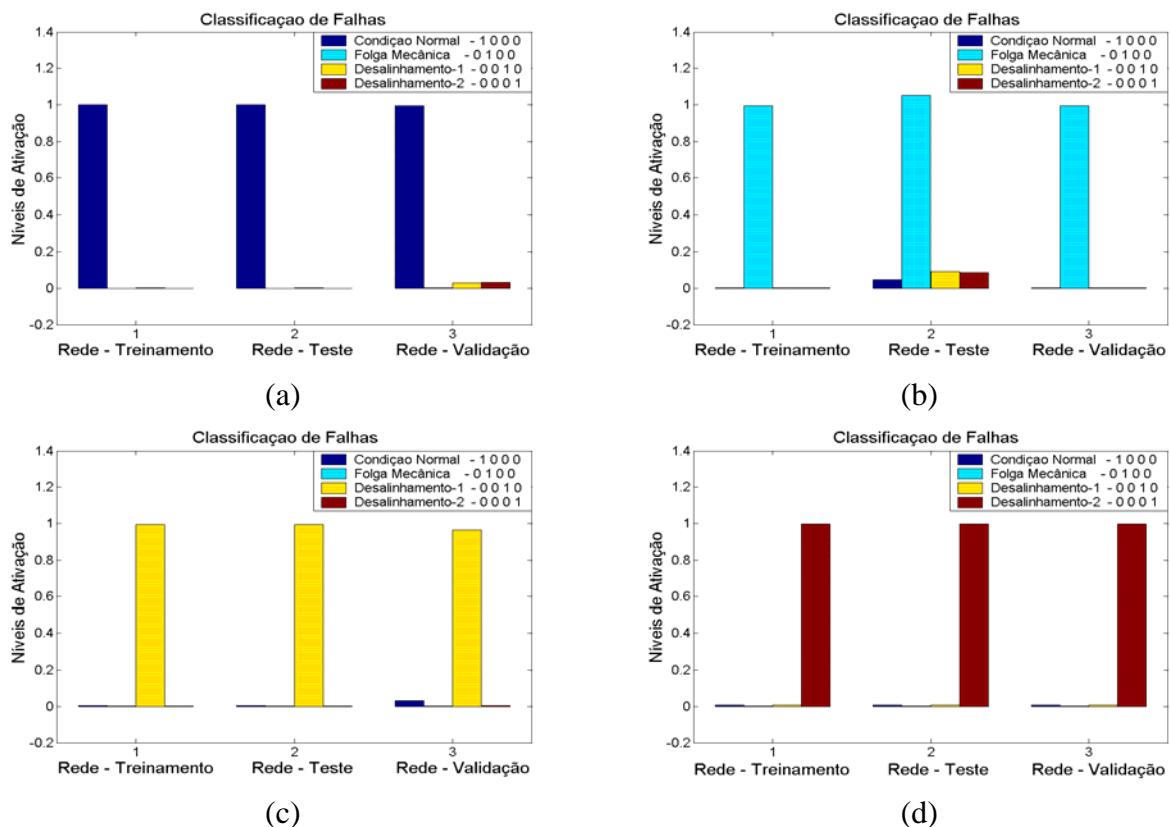


Figura 7. Comparação entre as Redes de Treinamento, Teste e Validação na Classificação de falhas, (a) Condição Normal, (b) Folga Mecânica, (c) Desalinhamento 1 e (d) Desalinhamento 2.

## 4. CONCLUSÕES

A WPT retém informação do sinal original de forma compacta. Este fato é muito importante na análise e processamento de sinais, principalmente na área de diagnóstico de falhas, pois pode-se reter informação do sinal somente naquela banda de freqüência onde as freqüências do defeito aparecem. Na prática, normalmente escolhe-se os packets que retém mais informação do sinal original e se descarta os packets que contém ruído e informações menos importantes.

A nova metodologia *Wavelet Packet Neural Network (WPNN)* pode ser utilizada satisfatoriamente como uma técnica alternativa de classificação e diagnóstico de falhas introduzidas em máquinas rotativas com eficiência de até 100%.

A WPNN é valida para aplicações em sinais estacionários e transientes, bem como apresenta as seguintes vantagens: é robusta à presença de ruídos contidos no sinal, é computacionalmente rápida e de custo razoável e de fácil implementação.

## 5. REFERÊNCIAS

- Al-Bedoor, B. O., 2000, “Transient Torsional and Lateral Vibrations of Unbalanced Rotors With Rotor-to-Stator Rubbing”, Journal of Sound and Vibration, Vol.229, No. 3, pp. 627-645.
- Chan, Y. T. 1996, “Wavelet Basics”. Kluwer Academic Publishers.
- Chui, C. K., 1992, “Wavelet Analysis and Its Applications, Vol. 1: An Introduction to Wavelets”. Boston, Academic Press.
- Daubechies, I., 1988, “Orthonormal Bases of Compactly Supported Wavelets”, Comm. Pure Appl. Math. Vol. 41, pp. 909-996.
- Gasch, R., 1993, “A Survey of the Dynamic Behavior of Simple Rotating Shaft With a Transverse Crack”, Journal of Sound and Vibration, Vol.160, pp. 313-332.
- Hamzaqui, N., Boisson, C. and Lesueur, C, 1998, “Vibro-Acoustic Analysis and Identification of Defects in Rotating Machinery, Part I: Theoretical Model”, Journal of Sound and Vibration, Vol. 216, No.4, pp. 553-570.
- Lépore, F. P., Santos, M. B. and Barreto, R. G., 2001, “Caracterização de Forças de Excitação em Máquinas Rotativas Usando Redes Neurais Combinadas com a Transformada de Wavelet”, XVI Congreso Brasileiro de Engenharia Mecânica - COBEM, Anais em CDROM, Uberlândia, M.G.
- Lucifredi, A., Mazzieri, C. and Rossi, M., 2000, “Application of Multiregressive linear Models, Dynamic Kriging Models and Neural Network Models to Predictive Maintenance of Hidroelectric Power Systems”, Mechanical Systems and Signal Processing, Vol. 14, No. 3, pp. 471-494.
- Mallat, S. G., 1998, “A Wavelet Tour of Signal Processing”, Academic Press, San Diego, USA.
- Misiti, M., Misiti, Y., Oppenheim, G. and Poggi, J.-M., 1997, “ Wavelet Toolbox – User’s Guide”, The MathWorks, Inc.
- Pacheco, R. P. and Steffen Jr., V., 1995, “Comportamento Dinâmico de Rotores no Regime Transiente”, XIII Congresso Brasileiro de Engenharia Mecânica, COBEM, CDROM, Belo Horizonte, M.G.
- Santiago, D. F. A. and Pederiva, R., 2003, “Application Of Wavelet Transform To Detect Faults In Rotating Machinery”, Proceedings of the 17 th International Congress of Mechanical Engineering - COBEM, Anais em CDROM, São Paulo, S.P.
- Santiago, D. F. A., 2004, “Diagnóstico de Falhas em Máquinas Rotativas Utilizando Transformada de Wavelet e Redes Neurais Artificiais”, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Tese de Doutorado, 2004.
- Santiago, D. F. A., Brito, J. N. and Pederiva, R., 2002, “Diagnóstico de Falhas em Máquinas Rotativas Utilizando Redes Neurais”, II Congresso Nacional de Engenharia Mecânica - CONEM, Anais em CDROM, João Pessoa, PB.

- Scheffer, C. and Heyns, P. S., 2001, "Wear Monitoring in turning Operations Using Vibration and Strain Measurements", Mechanical Systems and Signal Processing, Vol. 15, (6), pp. 1185-1202.
- Sekhar, A. S. and Prabhu, B. S., 1995, "Effects of Coupling Misalignment on Vibrations of Rotating Machinery", Journal of Sound and Vibration, Vol. 185, No. 4, pp. 665-671.
- Silva, A. A. Detecção e Análise Dinâmica de Falhas em Rolamentos. Departamento de Engenharia Mecânica, Escola de Engenharia de São Carlos, Universidade de São Paulo, Tese de Doutorado, 1999.
- Smalley, A. J., 1989, "The Dynamic Response of Rotors to Rubs During Startup", Journal of Vibration, Acoustics, Stress, and Reliability in Design, Vol. 111, pp. 226-233.
- Wauer, J., 1990, "Dynamics of Cracked Rotors, Literature Survey", Applied Mechanics Reviews, Vol. 43, pp. 13-17.
- Xu, M. and Marangoni, R. D., 1994, "Vibration Analysis of a Motor-Flexible Coupling-Rotor System Subject to Misalignment and Unbalance, Part I: Theoretical Model and Analysis", Journal of Sound and Vibration, Vol. 176, No. 5, pp. 663-679.
- Zhang, S., Ganesan, R. and Xistris, G. D., 1996, "Self-Organising Neural Networks for Automated Machinery Monitoring Systems", Mechanical Systems and Signal Processing, Vol. 10, No. 5, pp. 517-532.

## **CLASSIFICATION OF FAULTS IN ROTATING MACHINERY USING TRANSIENT RESPONSE AND WAVELET PACKET TRANSFORM.**

**Darley Fiácrio de Arruda Santiago**

CEFET / PI - Centro Federal de Educação Tecnológica do Piauí / UNED-Floriano

UNICAMP - Faculdade de Engenharia Mecânica - Departamento de Projeto Mecânico

Rua Francisco Urquiza Machado, 462, Floriano, PI., CEP: 64800-000 - darley@cefetpi.br

**Robson Pederiva**

UNICAMP - Faculdade de Engenharia Mecânica - Departamento de Projeto Mecânico

Caixa Postal: 6051 - Campinas, S.P., CEP: 13083-970 - robson@fem.unicamp.br

**Abstract.** *The study of the dynamic behavior and diagnostic of faults of the rotating machinery during run-up, shut-down and passage through critical speeds has become very important, mainly in machines that frequently starts-up and stops, and run with high speeds. Then, the monitoring vibration during transient state reveals information related to a fault of non-stationary nature that hardly would be diagnostic in the steady state. In this study the decomposition of the signal by Wavelet Packet Transform (WPT) is used as an alternative technique of extraction and compacting of parameters in independent frequency bands. The Shannon entropy formula is used to quantize the energy retained in the transient signal in each frequency band of the wavelet packet, as the presence of faults in the machine indicates significant levels of energy related to defect frequency. From the practical point of view, the utilization of signals, in time and frequency domain, obtained during steady state are not very suitable to be used as input data of neural networks. In this work are considered the levels of energy quantized in each frequency band of transient signal through wavelet packet as neural networks input parameters. One of the advantages of using this parameters as inputs in despite the high data compacting. The results show that the wavelet packet and neural networks can be used successfully as an alternative technique of diagnostic and classification of faults inserted in rotating machinery with high efficiency.*

**Keywords:** Rotating Machinery, Transient Response, Wavelet Packet, Neural Networks.