

UTILIZAÇÃO DE TÉCNICA DE PROCESSAMENTO DE SINAIS PARA MELHORAR O DESEMPENHO DE REDES NEURAIS ARTIFICIAIS

Edmilson R. O. Santos,

Edison Righeto,

João A. Pereira

Vicente L. Jr ,

Universidade Estadual Paulista-UNESP, Faculdade de Engenharia de Ilha Solteira – FEIS, Departamento de Engenharia Mecânica, 15385-000, Ilha Solteira-SP – Brasil.
Email: oliveira@dem.feis.unesp.br

Resumo

Uma das ferramentas que tem sido bastante investigada para localização e detecção de falhas em sistemas mecânicos são as Redes Neurais Artificiais-RNA. No entanto esta ferramenta depende enormemente do padrão de entrada utilizado durante o processo de treinamento da rede. Se o padrão de entrada não for adequado, as vantagens da aplicação de RNA poderão ser perdidas. A Transformada Wavelet (TW) é uma técnica que possui excelentes características de localização tempo-frequência e, proporciona maiores informações sobre as características do sinal. Portanto, em algumas aplicações, a utilização da TW na escolha do padrão de entradas do sinal poderá melhorar a eficiência da rede neural. A proposta deste trabalho é introduzir a Transformada Wavelet como um meio alternativo de extrair as características mais representativas dos dados de vibração e, utiliza-las como padrões de entrada no treinamento de Rede Neural Artificial. Neste caso, as informações a respeito das condições de funcionamento do sistema serão obtidas a partir dos coeficientes da TW afim de fornecer uma representação mais compacta dos sinais, quando comparado com sistemas convencionais como análise de Fourier.

Palavras-chave: Transformada Wavelet, Redutor, Redes Neurais Artificiais.

1. INTRODUÇÃO

O monitoramento e diagnose de máquinas e equipamentos é uma área emergente em engenharia. Ela envolve obter dados reais os quais informam as condições de operação da máquina. Em máquinas rotativas tais como redutores, ventiladores, e outras, os sinais de vibração são comumente usados para monitoramento. O controle da variação dos níveis do sinal é uma boa indicação do estado do sistema, porque o perfil de vibração pode mudar devido ao aparecimento de falha no sistema. Muitas técnicas já demonstraram um variado grau de sucesso em identificação de falhas utilizando sinais de vibração. Mas a maior parte destas técnicas não são adequadas para sinais transientes. Uma das mais recentes técnicas de processamento de sinais, Transformada Wavelet , tem-se mostrado mais adequada. A TW de um sinal temporal é uma expansão em termos de uma família de funções geradas a partir de uma única função base “wavelet mãe” por dilatação e translação. O termo dilatação significa expandir ou comprimir a “wavelet mãe” de forma que esta função proporcione uma visão mais detalhada ou não do sinal. Já a translação é uma forma que função Wavelet, alterada pela

dilatação, utiliza para percorrer o sinal por toda sua duração. A aplicação da TW para diagnosticar falhas em máquinas já foi utilizada em diversas situações, como por exemplo nos trabalhos dos seguintes autores: Hazarika *et al.* (1997), Lee e White (1997), Newland (1993), Paya *et al.* (1997) e Pettrilli *et al.* (1995). Embora, uma inspeção visual de certas características da análise espectral seja adequada para identificar falhas, um método menos subjetivo e confiável é necessário para a diagnose do sinal de vibração, especialmente quando o avanço da falha é pequeno ou existem múltiplas falhas no sistema (Paya, *et al.* 1997). O problema de detecção de falhas neste caso é essencialmente um reconhecimento de padrão; dados do sistema sem defeito devem ser distinguíveis dos dados de um sistema com falha. Redes neurais artificiais são técnicas computacionais para identificação de padrões através de modelos matemáticos inspirados nos neurônios biológicos dos organismos inteligentes (Wasserman, 1989). As RNAs são bem conhecidas por suas capacidades de identificar e classificar, sendo que nos últimos anos tem atraído a atenção de muitos pesquisadores, principalmente no campo da engenharia elétrica e controle. A proposta deste trabalho é introduzir a Transformada Wavelet como um meio alternativo de extrair características a partir de dados de vibração ocasionados por falhas de um redutor e, assim, servir como um padrão de entrada para o treinamento de uma rede neural artificial. Um padrão de entrada com informações mais específicas, através do emprego da análise Wavelet, poderá melhorar o desempenho do sistema de monitoramento da condição de operação das máquinas. O tipo de rede usada no presente estudo foi a rede neural artificial supervisionada de multi camadas, com o método de treinamento retro propagação. Os dados utilizados na avaliação da metodologia proposta foram dados simulados gerados a partir de um modelo matemático com base em parâmetros reais de um redutor.

2. TRANSFORMADA WAVELET

A transformada Wavelet (TW) é definida de forma semelhante a transformada de Fourier (TF),

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega) e^{i\omega t} d\omega, \quad (1)$$

e

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) e^{-i\omega t} dt. \quad (2)$$

A Eq. (2) é chamada de transformada de Fourier da função $f(t)$ e a Eq. (1) é chamada de transformada de Fourier inversa. A TF converte os dados no domínio do tempo para o domínio de frequência através de senos e cosenos como funções base, e estas apresentam características médias da função $f(t)$. A TW é definida de maneira similar a TF. Entretanto, em lugar de utilizar harmônicos, a TW utiliza uma família de funções geradas a partir de uma única função base chamada de “wavelet mãe”, a qual pode ser expandida/comprimida e transladada ao longo do tempo de duração do sinal. Assim, com essa família de funções pode-se ter uma visão mais detalhada ou não de $f(t)$.

A TW converte dados no domínio do tempo para o domínio tempo-escala, onde pode ser visualizado características localizadas do sinal original. A Eq. (3) expressa uma família de funções que pode ser utilizadas para decompor a função temporal, cujo o parâmetro real $a > 0$ permite uma expansão ou compressão e o parâmetro b a translação da função base:

$$w_{(a,b)} = a^{-1/2} W\left(\frac{t-b}{a}\right) \quad (3)$$

$W(t)$ representa a wavelet mãe. Uma função $f(t)$, $t \in [0, T]$, pode ser decomposta em uma soma de wavelets em um número finito de escalas como:

$$f(t) = w_0 + \sum_{j=0}^{\infty} \sum_{k=0}^{2^j-1} w_{2^j+k} W(2^j t - kT), \quad (4)$$

e

$$w_0 = \int_0^T f(t) dt, \quad (5)$$

$$w_{2^j+k} = \int_0^T f(t) W(2^j t - kT) dt. \quad (6)$$

O parâmetro j descreve os diferentes níveis das wavelets. O parâmetro k é responsável pela posição das wavelets em cada nível, por isso ele cobre o intervalo de $k=0$ à $k=2^j-1$. O comprimento dos dados a ser transferidos do domínio do tempo deve ser potência de dois (isto é 2^n). Existem muitos tipos de wavelets mas, para o presente estudo será utilizado a Daubechies (db4), (Daubechies, 1992).

3. REDES NEURAS ARTIFICIAIS

As RNAs são inspiradas em sistemas nervosos biológicos, portanto, elas são compostas de elementos que desempenham, de uma forma análoga, as funções mais elementares dos neurônios biológicos. Modelos de redes neurais tem um maior potencial em áreas tais como reconhecimento de voz e imagem onde muitas hipóteses são colocadas em paralelo, altas velocidades computacionais são requeridas e, os sistemas disponíveis estão longe de igualar o desempenho humano. Modelos de redes neurais exploram muitas hipóteses competindo simultaneamente e utilizando maciçamente redes paralelas compostas de muitos elementos computacionais conectados por ligações com ponderações variáveis. Os elementos computacionais ou nós utilizados em modelos de redes neurais são funções não lineares.

O nó mais simples tem entradas ponderadas e passa as informações para o próximo nível através de uma função de ativação. O desenvolvimento das redes levou a utilização de vários tipos de funções de ativação. As principais são: degrau, rampa, logística, tangente hiperbólica e gaussiana (Wasserman, 1989). Modelos de redes neurais são especificados pela configuração da rede, características nodais e, treinamento ou aprendizado de regras. Estas regras especificam um conjunto inicial de ponderações e indica como a ponderação deve ser adaptada durante o uso para melhorar o seu desempenho. Tanto a escolha da configuração da rede, como as regras de treinamento são tópicos ainda em desenvolvimento.

Os métodos de treinamento de uma rede neural podem ser divididos em duas categorias: aprendizado supervisionado, e aprendizado não supervisionado. O primeiro tipo de aprendizado é o mais comum e empregado nos diversos tipos de redes neurais existentes. O aprendizado supervisionado consiste em apresentar a rede neural uma série de dados de entrada e as respectivas saídas esperadas. Um algoritmo será empregado para ajustar os pesos

das conexões entre os neurônios pelo cálculo do erro, isto é, a diferença entre a saída esperada e aquela efetivamente calculada. Entre os algoritmos para o cálculo destaca-se o algoritmo de retro propagação do erro.

Este primeiro método de treinamento é denominado de supervisionado pois é necessário apresentar a rede as respostas esperadas. Uma desvantagem deste tipo de aprendizado é a necessidade de se dispor de conjunto de dados de treinamento. Dependendo do tamanho da rede serão necessários vários casos de treinamento para que todos os pesos sejam obtidos de maneira ideal. Outro tipo de treinamento é denominado não supervisionado. Neste caso, não é necessário apresentar à rede as respostas esperadas. No treinamento não supervisionado os pesos são ajustados para que as entradas similares produzam saídas similares. O algoritmo de treinamento extrai regularidades estatísticas do conjunto de dados de treinamento.

4. SINAIS DE VIBRAÇÃO SIMULADOS

O principal objetivo deste estudo é demonstrar a aplicabilidade da metodologia proposta para o reconhecimento das condições de operação de um sistema utilizando dados reais. Entretanto, afim de testar a potencialidade e limitações do método, será avaliado inicialmente com sinais simulados para um redutor com um par de redução. Os sinais utilizados são classificados por famílias (cada uma delas com 8 sinais), as quais representam sinais normais e defeituosos. Cada família representa uma condição do redutor, e o que difere um sinal do outro, em cada família, é o efeito causado pela introdução de um ruído branco no sinal. Os sinais propostos estão definidos para um tempo de aquisição de 0.128 s e amostrados com 1024 pontos. Os sinais simulados utilizam dados de um redutor de engrenagens helicoidais de um único par de redução, Tab. 1.

Tabela 1. Características geométricas do redutor

Número de dentes do pinhão	44
Número de dentes da coroa	95
Frequência do eixo de entrada	30 (Hz)
Frequência do eixo de saída	14 (Hz)
Frequência de engrenamento	1320 (Hz)

Cada sinal da família de sinais normais é constituído da frequência de engrenamento, frequência de giro (pinhão) e 5% de ruído branco, Fig. 1.




Figura 1. Sinal Normal

Um sinal da família de sinais defeituosos (1) tem as mesmas características de um sinal normal, frequência de engrenamento, frequência de giro (pinhão), 5% de ruído branco, e adicionalmente um impulso a cada 256 pontos (ou 0.032 s) representando o efeito de um dente quebrado, Fig. 2.




Figura 2. Sinal Defeituoso (1)

Um sinal da família de sinais defeituosos (2) tem as mesmas características de um sinal normal, frequência de engrenamento, frequência de giro (pinhão), 5% de ruído branco, e adicionalmente um impulso a cada 64 pontos (ou 0.008 s) representando um defeito de rolamento, Fig. 3.




Figura 3. Sinal Defeituoso (2)

5. METODOLOGIA

As famílias de sinais simulados são pré processadas via transformada wavelet discreta (DWT), ou seja, cada sinal de uma família é decomposto em 8 componentes, Fig. 4. Parte dessas componentes são responsáveis pelas baixas frequências (aproximações) e as outras pelas altas frequências (detalhes).




Figura 4. Decomposição de um sinal normal pela DWT

Mediante a seleção do nível e do tipo de wavelet pode-se decompor os sinais com mais ou menos componentes e também com maior ou menor resolução. Um sinal da família de sinais normais decomposto foi escolhido como referência para estabelecer a correlação entre seus componentes e os componentes dos demais, e também em relação aos componentes das

outras famílias (defeituosos (1) e (2)). Assim, a correlação entre pares de sinais decompostos geram vetores com dimensão 8×1 , os quais são utilizados como entrada da RNA. Esses vetores representam quanto um sinal assemelha-se com o sinal escolhido como referência. Parte desses vetores foram utilizados para o treinamento da RNA (arquivos Aq1, Aq1.3 e Aq2.6) e os demais, como relacionado na tab. 2, foram utilizados para testar a capacidade de reconhecimento da rede. A RNA supervisionada de multi camadas, utilizou o algoritmo de treinamento retro propagação, com função tangente hiperbólica. A camada intermediária foi estabelecida através de tentativas, e assim pela experiência adquirida chegou-se a 10 neurônios com o melhor desempenho para o treinamento da RNA. Afim de simplificar os resultados de classificação ou distinção entre tipos diferentes de falhas, as saídas designadas para cada situação são as seguintes:

1. sinal normal \Rightarrow saída 0;
2. sinal defeituoso (1) \Rightarrow saída 0.5;
3. sinal defeituoso (2) \Rightarrow saída 1.0 .

6. RESULTADOS

Na tab. 2 estão todas as respostas da RNA para os vários testes de reconhecimento dos vetores não utilizados durante o treinamento. Para o primeiro bloco referente aos sinais normais, pode-se observar que as respostas da RNA foram as esperadas (aproximadamente zero). As respostas da RNA para o segundo e terceiro bloco, também foram muito satisfatórias, ou seja, os arquivos que apresentam as piores resposta ainda mostram uma identificação próxima do esperado, ou seja, apenas uma diferença de 2% e 3% respectivamente.

Tabela 2. Arquivos utilizados para testar a RNA

Famílias de Sinais	Arquivos	Saída da Rede
N O R M A I S	Aq2	0.0007
	Aq3	0.0023
	Aq4	0.0004
	Aq5	0.0007
	Aq6	0.0023
	Aq7	0.0004
	Aq8	0.0005
	D E F E I T O (1)	Aq1.1
Aq1.2		0.5186
Aq1.4		0.5077
Aq1.5		0.5196
Aq1.6		0.5186
Aq1.7		0.5077
Aq1.8		0.5146

D E F E I T O (2)	Aq2.1	0.9735
	Aq2.2	0.9783
	Aq2.3	0.9794
	Aq2.4	0.9730
	Aq2.5	0.9684
	Aq2.7	0.9786
	Aq2.8	0.9789

Os resultados apresentados mostram que a TW é uma ferramenta de pré processamento de sinais de vibração muito eficiente, e que estes dados podem ser utilizados como entradas para uma RNA com objetivo de melhorar o desempenho desta na identificação dos tipos de falhas. Embora, não foi feito uma comparação direta com outros tipos de ferramentas, um trabalho desenvolvido por Petrilli *et al.* (1995), mostrou que RNAs que utilizavam sinais pré processados pela TW para o seu treinamento obteve uma convergência muito mais rápida do que os mesmos sinais pré processados pela FFT. Isto ocorre porque a capacidade da DWT em analisar transientes e guardar informações importantes do sinal permiti associar as falhas com os respectivos componentes, assim a RNA pode ter informações mais precisas e consequentemente um melhor diagnóstico.

7. CONCLUSÃO

Os resultados apresentados e discutidos neste trabalho mostram que o desempenho da DTW como um pré processador dos sinais de vibração foi satisfatório e também demonstra que ela pode ser utilizada como ferramenta para detectar ocorrências de variações bruscas.

A análise via DWT requer uma familiaridade do usuário com a técnica, pois para processamento do sinal deve-se determinar primeiro qual tipo de wavelet é mais adequada para que a extração das característica importantes do sinal sejam a melhor possível. O tipo de wavelet utilizada foi a db4, a qual também mostrou-se ser eficiente no processamento de sinais em outros trabalhos.

Uma combinação da DWT e RNA é uma técnica eficaz e adequada para o monitoramento contínuo de máquinas. O próximo passo será utilizar a técnica para a detecção de falhas utilizando dados experimentais.

8. AGRADECIMENTOS

Os autores agradecem à CAPES pelo apoio financeiro para desenvolvimento do trabalho.

9. REFERÊNCIAS

- Daubechies, I., 1992, “Ten Lectures on Wavelets”, CBMS – NSF Regional Conference Series In Applied Mathematics SIAM, Philadelphia.
- Hazarika, N, Chen, J. Z., Tsoi, A. C. and Sergejew, A., 1997, “ Classification Of EEG Signals Using The Wavelet Transform”, Elsevier, Signal Processing, Vol. 59, pp. 61-72.

- Lee, S-K., White, P. R., 1997, “ Fault Identification for Rotating Machinery Using Adaptive Signal Processing and Time-Frequency Analysis”, Proceedings of DETC’97, Sacramento, California.
- Newland, D., 1993, “Wavelet Analysis of Vibration”, The 16th Annual Energy Sources Technology Conference and Exhibition, Structural Dynamics and Vibration, Houston, Texas, USA, 31 january – 4 february.
- Paya, B. A., Esat, I. and Badi, M. N. M., 1997, “Artificial Neural Network Based Fault Diagnostics of Rotating Machinery Using Wavelet Transforms as a Preprocessor”; Mechanical System and Signal Processing, Vol. 11, N^o: 5, pp: 751-765.
- Petrilli, O., Paya, B., Esat, I. I. and Badi, M. N. M., 1995, “ Neural NetWork Based Fault Detection Using Different Signal Processing Techniques As Pre-Processor”, Structural Dynamics and Vibration, ASME, Vol. 70.
- Staszewski, W. J., Worden, K., 1993, “Classification of Faults in Spur Gears”, The World Congress on Neural Networks, Portland Oregon, 11 – 15.
- Wasserman, Philip D., 1989, “ Neural Computing Theory And Practice”.