

DETEÇÃO DE FALHAS EM MÁQUINAS ROTATIVAS ATRAVÉS DE CARACTERÍSTICAS DO SINAL DE VIBRAÇÃO E REDE SOFM

GERALDO LUIS BEZERRA RAMALHO*, PEDRO PEDROSA REBOUÇAS FILHO*, CELSO ROGÉGIO SCHMIDLIN*, SAMUEL VIEIRA DIAS*

**Instituto Federal de Educação, Ciência e Tecnologia do Ceará
Campus Maracanaú - Av. Parque Central s/n
Maracanaú, Ceará, Brasil*

Emails: gramalho@ifce.edu.br, pedrosarf@ifce.edu.br, celso@ifce.edu.br, samueldias@ifce.edu.br

Abstract— The condition monitoring of industrial machinery provides information about the operating status of equipment which allows planning maintenance work before a failure occurs. The methods of early detection of faults traditionally employ the Fourier transform to perform spectral analysis of vibration signals obtained with piezoelectric accelerometers. In this paper we propose an approach based on Haar wavelet Transform for extracting features of a vibration signal obtained with MEMS accelerometers. In previous work we demonstrate how to obtain valuable descriptors to detect changes in equipment condition. This paper presents results from experimental studies demonstrating the use of those descriptors to failure identification using a SOFM network.

Keywords— machine condition, fault detection, MEMS sensors, SOFM network.

Resumo— O monitoramento da condição de máquinas industriais fornece informações sobre o estado de operação do equipamento o que permite planejar uma intervenção de manutenção antes que uma falha ocorra. Este trabalho propõe uma abordagem de monitoramento de condição de máquina baseada na extração de características de um sinal de vibração obtido com acelerômetros MEMS. As características extraídas da decomposição do sinal de vibração por Transformada Haar e dimensão fractal são utilizadas para treinar a rede SOFM a fim de obter protótipos descritores dos padrões encontrados no sinal de vibração. Através do resultado de experimentos é demonstrada a viabilidade da metodologia para aplicação na detecção e identificação de falhas.

Palavras-chave— condição de máquina, inspeção não destrutiva, sensores MEMS, rede SOFM

1 Introdução

Trabalhos recentes têm investigado o uso de acelerômetros MEMS (*Microelectromechanical System*) em substituição aos acelerômetros piezoelétricos. Sensores MEMS são aplicados no monitoramento de ventiladores (Chen et al., 2010) e de sistemas de transmissão de aerogeradores. No trabalho de Maruthi and Vittal (2005) foram utilizados acelerômetros MEMS em substituição aos tradicionais acelerômetros piezoelétricos no monitoramento de falhas em motores monofásicos gaiola de esquilo. Os autores realizaram análise espectral de falhas a partir do sinal do acelerômetro MEMS e através da assinatura de corrente do motor.

A investigação de métodos diferentes de análise e processamento do sinal de vibração toma espaço nos trabalhos científicos mais recentes. Uma revisão de métodos de monitoramento de sistemas é apresentada por Hassan (2013). Neste trabalho, os autores investigam diferentes aplicações nas quais são empregadas redes neurais tanto no controle quanto no monitoramento de sistemas de potência. Em Paiva et al. (2009), foi utilizada a Transformada *wavelet* (TW) na filtragem do sinal com o objetivo de detecção de falhas em sistemas dinâmicos. No trabalho de Jiang and Liu (2011), foi investigado o monitoramento de condição de máquina através da extração de características que indicam a deterioração do equipamento.

Li et al. (2010) e Li et al. (2011) obtiveram êxito na detecção de falhas em caixas de engrenagens utilizando *wavelet*.

Máquinas de aprendizagem e redes neurais têm sido bastante exploradas nesse tipo de aplicação. Konar and Chattopadhyay (2011) empregaram o uso de extração de características do sinal de vibração baseado em transformada *wavelet*. A partir das decomposições *wavelet* foram extraídas medidas e posteriormente estas medidas foram classificadas utilizando uma máquina de vetor de suporte (SVM, do inglês *support vector machine*). Em Chakraborty et al. (2012) foi proposto um método baseado em mapas de características auto-organizáveis (SOFM, do inglês *auto-organizing feature maps*) e funções de base radial (RBF, do inglês, *radial basis function*).

O presente trabalho propõe um método de monitoramento de falhas com base na extração de características de um sinal de vibração obtido com acelerômetros MEMS de largura de banda estreita que podem ser obtidos a uma fração do custo de sensores piezoelétricos. As características do sinal são analisadas e classificadas conforme o estado de operação do equipamento monitorado. A análise do sinal é feita a partir de técnicas de extração de características utilizando decomposições por transformada *wavelet* Haar e dimensão fractal. As características são utilizadas para treinar uma rede neural de aprendizagem não super-

visionada, a saber mapas de características auto-organizáveis (SOFM, do inglês *self-organized feature maps*) (Kohonen, 2001). Os resultados preliminares, mostram que defeitos como folgas de acoplamento ou de fixação de motores são passíveis de serem caracterizados com a metodologia proposta, utilizando os protótipos da rede SOFM associados aos históricos de manutenção do equipamento.

2 Detecção de falhas

Nesta seção é apresentado um método alternativo à análise espectral do sinal de vibração, classicamente baseada na análise espectral pela Transformada de Fourier. A metodologia, ilustrada na Figura 1, baseia-se em descritores que medem o grau de complexidade do sinal de vibração de um equipamento, obtido com acelerômetros MEMS, proposto em Ramalho et al. (2012). Os descritores são extraídos do sinal de vibração, utilizando o cálculo da Dimensão Fractal, além da energia e entropia dos primeiros níveis de decomposição *wavelet* desse mesmo sinal.

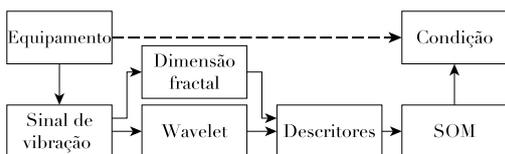


Figura 1: Metodologia para detecção da condição e caracterização da falha.

2.1 Decomposição do sinal de vibração

Uma Transformada *wavelet* Discreta (TWD) é utilizada como estratégia de decomposição do sinal de vibração em níveis de detalhes visando a extração das características do sinal. Adotou-se a Transformada Haar (também conhecida como daubechie-1) (Mallat, 1999) que possui um algoritmo computacional bastante rápido baseado apenas em operações algébricas simples. A principal vantagem do uso dessa estratégia para a análise do sinal advém do fato de que o sinal pode ser decomposto em diversos níveis de aproximação e detalhes. Este método não substitui a análise espectral obtida com a FFT, mas oferece uma alternativa viável para análise das características contidas no sinal.

Considere x um sinal unidimensional periódico discreto que representa o sinal de vibração obtido com um acelerômetro MEMS a uma taxa de amostragem S durante um tempo T . Na Transformada *wavelet* Haar discreta, os coeficientes de aproximação e de detalhes do primeiro nível de decomposição de um sinal discreto x são definidos,

respectivamente, como

$$a_1[i] = (x[2(i-1) + 1] + x[2i])/2 \quad (1)$$

e

$$d_1[i] = x[2(i-1) + 1] - x[2i], \quad (2)$$

em que, $i = 1, 2, \dots, N/2$, sendo N o número de amostras do sinal. As decomposições seguintes utilizam a Eq. 1 e Eq. 2, calculadas sobre a componente de aproximação do nível anterior. O processo se repete para o nível seguinte até seja atingido um critério de parada. A Eq. 1 pode ser vista como um filtro passa baixa, enquanto a Eq. 2 é interpretada como um filtro passa alta.

Por ser uma *wavelet* decimada, a cada decomposição, são produzidos coeficientes de detalhes e de aproximação, ambos com metade do tamanho do sinal no nível anterior. Isto significa que, para cada nível de decomposição, são obtidos detalhes em diferentes escalas. A Figura 2 ilustra o procedimento de decomposição de um sinal em seus componentes *wavelet* de aproximação e de detalhes em três níveis. Essa abordagem possibilita uma análise multiescala do sinal de vibração.

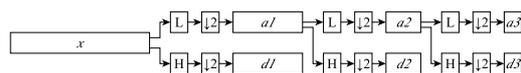


Figura 2: Esquema de decomposição wavelet em sucessivos componentes de aproximação (a_j) e componentes de detalhes (d_j).

2.2 Medidas para caracterização do sinal

Um sinal de vibração apresenta um padrão estocástico bastante complexo. Esta complexidade pode ser descrita a partir de métricas extraídas das decomposições *wavelet* do sinal.

Sejam a_j e d_j , para $j = 1, 2, \dots, D$, os coeficientes de aproximação e coeficientes de detalhes *wavelet* do sinal x obtidos a partir da Eq. 1 e Eq. 2 num esquema como o ilustrado na Figura 1. Os coeficientes de aproximação do sinal de vibração podem ser vistos como componentes de energia cinética e potencial, representando assim a energia total do sinal, que é proporcional à intensidade da vibração. Os coeficientes de detalhes podem ser interpretados como derivadas discretas da aceleração e representam a taxa de variação dessa aceleração. A partir dessas suposições, é possível definir algumas medidas para as decomposições do sinal a fim de obter três descritores, descritos como segue:

En: a energia obtida a partir dos coeficientes de detalhes do sinal. O descritor *En* fornece uma estimativa indireta da intensidade de vibração através do nível de variação dos coeficientes de detalhes d_j , de tamanho D , determinado pela

expressão

$$En = \frac{1}{D} \sum_{i=1}^D d_j [i]^2 \quad (3)$$

Et: a entropia aproxima o grau de desorganização dos coeficientes de detalhes do sinal de vibração. Essa medida é sensível à presença de harmônicas. A entropia é obtida a partir da densidade de propabilidade p do conjunto de coeficientes d_j , para $j = 1$, por meio da expressão

$$Et = -10 \log p(d_j). \quad (4)$$

DF: a dimensão fractal é uma métrica utilizada para medir o grau de complexidade do sinal. O descritor *DF* mede o comprimento do sinal caso ele pudesse ser desdobrado em uma linha reta.

O cálculo da dimensão fractal é obtido com o algoritmo de contagem de caixas (*box counting*) cujos detalhes são apresentados em Falconer (2003). O valor da dimensão fractal (*DF*) de um sinal é determinado pela expressão

$$DF = \log N_b / \log R, \quad (5)$$

em que N_b é o número de caixas (*boxes*) δ -dimensionais de tamanho R necessárias para cobrir os elementos não nulos do sinal. Para o caso particular de um sinal unidimensional ($\delta = 1$), as caixas são representadas por segmentos de reta contidos no sinal. As caixas possuem tamanhos em potência de 2, ou seja, $R = 1, 2, 4, \dots, 2^P$, sendo P o menor número inteiro que satisfaz $\max(D \leq 2^P)$, sendo D o número de amostras do sinal.

As medidas extraídas das decomposições do sinal de vibração compõem um vetor $\mathbf{k} = \{k_1, k_2, \dots, k_n\}$ num espaço de características n -dimensional. Para o caso particular deste artigo, é utilizado um vetor com apenas três atributos, ou seja $n = 3$.

2.3 Mapa de características

As redes neurais do tipo mapa auto-organizáveis (SOM, do inglês *self-organized maps*) são algoritmos de aprendizagem competitiva não supervisionada que tem sido utilizados em diversas aplicações, que vão desde o reconhecimento de padrões até a mineração de dados (Kohonen, 2001). Numa etapa posterior, uma rede SOFM é treinada e os protótipos obtidos são correlacionados com dados históricos de manutenção do equipamento para caracterizar o tipo de falha.

No monitoramento de condição de máquina, a aquisição do sinal de vibração e as características extraídas desse sinal são constantemente avaliados. A grande quantidade de vetores de características coletada torna necessário automatizar o processo de agrupamento em padrões para permitir uma melhor visualização e interpretação desses padrões.

Neste trabalho, adotou-se a rede SOM pelas suas características de preservação da topologia e redução de dimensionalidade. Além disso, o algoritmo SOM é flexível o bastante para ser transformada em um classificador de padrões, quantização vetorial e aprendizagem ativa (Kohonen, 2001). Quando a rede SOM é utilizada para produzir uma representação do espaço de características, temos um mapa de características auto-organizável (SOFM, do inglês *self-organized feature map*).

A forma mais comum de garantir a convergência de uma rede SOFM é decrementar as taxas de aprendizagem e a taxa de atualização dos vizinhos ao longo do tempo. Quando essa atualização é reduzida somente ao vencedor, a SOFM se torna uma quantização vetorial. Numa rede SOFM bidimensional cada protótipo n -dimensional $\mathbf{w}_i = \{w_1, w_2, \dots, w_n\}$, $i = 1, 2, \dots, m$, é associado com um nó (c, l) da malha. A malha de visualização tem correspondência um-para-um com os índices associados com os vetores dos protótipos, ou seja, possui m nós. Na rede SOFM, é encontrado o vetor vencedor que melhor representa o vetor de entrada.

Dado um vetor de características $\mathbf{k} = \{k_1, k_2, \dots, k_n\}$, a expressão geral que define a adaptação dos pesos da rede SOFM, ou seja do vetor de protótipos $\mathbf{w}_i = \{w_1, w_2, \dots, w_n\}$, é determinada por

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) + h_{cl}(t)[\mathbf{k}(t) - \mathbf{w}_i(t)], \quad (6)$$

em que $t = 0, 1, 2, \dots$ é um inteiro que identifica a época atual de treinamento no tempo discreto; $h_{cl}(t) = \alpha(t) \exp(-\frac{\|r_c - r_l\|^2}{2\sigma^2(t)})$ é uma função de vizinhança comumente utilizada, que define quais os pesos serão atualizados; $\alpha(t)$ é a taxa de aprendizagem e $\sigma(t)$ é um raio que define a abrangência da vizinhança. r_c e r_l são os vetores que correspondem à posição dos nós da malha. Para acelerar a convergência, faz-se $h_{cl}(t) \rightarrow 0$ quando $t \rightarrow \infty$ e os vetores \mathbf{w}_i são inicializados com valores aleatórios antes do treinamento.

Uma vez que os padrões podem ser diferenciados graficamente, é possível encontrar protótipos representativos de cada padrão através de algoritmos de aprendizagem não supervisionada. Quando os dados históricos dos padrões de vibração possuem correlação com um histórico de manutenção do equipamento monitorado, é possível utilizar os protótipos da rede SOFM para rotular cada padrão que for detectado.

A rotulação é feita encontrando-se o melhor par (BMU, em inglês *best match unity*) entre cada vetor de característica \mathbf{k}_{novo} e os protótipos da rede SOFM \mathbf{w}_i . Nesta etapa, utiliza-se uma função de distância $dist(\cdot)$ como critério, em geral, a distância Euclideana. Assim, um padrão representado por um vetor de características \mathbf{k}_{novo} recebe o rótulo do protótipo mais próximo satisfazendo a

seguinte expressão

$$rot_{\mathbf{k}_{novo}} = \arg \min_{i=1,2,\dots,m} \{dist(\mathbf{k}_{novo}, \mathbf{w}_i)\}, \quad (7)$$

em que $dist(\cdot)$ é uma função de distância entre dois vetores.

A preservação de topologia da rede SOFM se mostra adequada a essa tarefa porque é importante que os protótipos mantenham uma relação topológica entre si. Por exemplo, quando um padrão desconhecido é detectado, é possível tentar descrever a sua trajetória de mudança de condição e, assim, determinar as possíveis causas que produziram aquele padrão de vibração específico. Além disso, é possível decidir quando o padrão desconhecido deve ser associado a um padrão existente ou ser utilizado para produzir um novo padrão.

A partir dos protótipos da SOFM é possível obter duas informações adicionais reduzidas a um espaço bidimensional. O treinamento da SOFM para cada condição isolada, utilizando apenas 2 neurônios, fornece uma representação no espaço bidimensional da intensidade (v) e da direção (θ) da dispersão dos descritores. Estas são informações importantes porque descrevem o comportamento dos descritores para as diferentes condições e podem ser utilizadas na identificação do tipo de falha.

3 Modelo experimental

A medição da vibração foi realizada com um acelerômetro MEMS triaxial (Freescale MMA7361). O sensor possui banda de frequência pequena 400Hz, faixa de medição $\pm 1,5g(\pm 1,6V)$ e sensibilidade de 100 mV/g, adequados para os níveis de intensidade e de frequência de vibração monitorados. A frequência de ressonância do sensor é da ordem de 6 kHz, bem abaixo da faixa de frequências medidas. A sensibilidade transversal (*cross axis*) do sensor é de $\pm 5\%$.

O sinal de vibração foi obtido com um módulo de aquisição de dados de 14 bits (National Instruments NiDAQ). Utilizou-se uma taxa de amostragem de 1000 Hz e cada medição teve a duração de 0,25 segundo. Todas as medições foram realizadas com o motor em regime permanente.

Os experimentos foram conduzidos em uma bancada de ensaios composta por um motor de indução trifásico com rotor em gaiola, de 1,5 cv, 220 V (ligação em Y), 4,31 A, 60 Hz (1700 rpm). O acionamento do motor foi feito por um conversor de frequência de 1,5 cv com frequência de comutação de 5kHz. Para simulação de carga, foi utilizado um freio eletrodinâmico com acionamento ajustável, equipado com dinamômetro com escala de 0 a 100 N. O acelerômetro MEMS foi fixado à carcaça do motor sobre o mancal dianteiro do eixo. Nessa posição, a medição do sinal de vibração é realizada no sentido radial vertical.

Para estes experimentos, foi desenvolvido um *script* no programa MATLAB, responsável pela realização da leitura *on line* do coletor de dados, processamento do sinal e exibição dos gráficos. O *script* emprega a Eq. (1) e Eq. (2) no cálculo de 7 níveis de decomposições *wavelet* Haar sobre o sinal de vibração. Os valores de energia (En) são obtidos com a Eq. (3), aplicadas sobre os coeficientes de detalhes das decomposições *wavelet* do sinal de vibração. A entropia (Et) do sinal, obtida com a Eq. (4), é calculada sobre o primeiro nível de detalhes da decomposição *wavelet*. O cálculo da dimensão fractal (DF), obtido com a Eq. (5), é realizado sobre o sinal de vibração. Os três atributos são utilizados para formar um vetor de características da condição de operação do equipamento.

4 Resultados e discussão

Foram realizados quatro ensaios diferentes. Cada ensaio é composto pela coleta de 10 medições do sinal de vibração, cada uma com 244 amostras. A coleta foi feita com o motor em estado permanente para uma determinada condição de operação definida por parâmetros como velocidade de rotação, intensidade de carga e a existência ou não de uma falha mecânica ou elétrica. Os dados foram processados e exibidos em gráficos na tela de um computador, utilizando-se *scripts* desenvolvidos no programa MATLAB.

Dois tipos de falhas mecânicas foram simuladas: i) folga no acoplamento entre eixo do motor e carga, simulando uma condição de deterioração do elemento de amortecimento; ii) folga na fixação da base do motor, simulando uma condição de degradação estrutural. Para efeito de referência, também foram realizadas medições com o motor parado e em operação sem carga. As falhas mecânicas foram aplicadas no intervalo entre medições.

Foi analisado o comportamento do equipamento para diferentes níveis de carga nas duas condições de falha. Cada medição foi identificada com os códigos apresentados na Tabela 1. Os resultados foram separados em quatro classes, indicando motor parado, funcionamento normal sem carga, funcionamento normal com carga e funcionamento em falha com carga.

Os dados obtidos neste ensaio são exibidos na Figura 3. Cada condição do equipamento possui N amostras do sinal de vibração, o que corresponde ao número de diferentes vetores de características \mathbf{k} . Para facilitar a interpretação visual, apenas 2 das 3 características estão representadas. Os tons dos marcadores indicam tipos diferentes de falhas. A Figura 3 ilustra quatro condições de operação, sendo duas normal (A e B) e duas em falha (C e D). Essas condições estão representadas pelo valor médio $\bar{\mathbf{k}} = \sum_{j=1,2,\dots,N} \mathbf{k}_j / N$ dos vetores de características de N amostragens. Neste expe-

Cod.	Condição	rpm	N.m
A	motor parado	-	-
B	motor desacoplado da carga	1797	-
C ₁		1797	0,0
C ₂	motor acoplado à	1782	1,7
C ₃	carga	1763	3,3
C ₄		1744	5,0
D ₁		1797	0,0
D ₂	motor com carga e	1782	1,7
D ₃	folga na base	1763	3,3
D ₄		1744	5,0

rimiento, foram realizadas $N = 10$ amostragens do sinal de vibração.

Percebe-se que as falhas B e D na Figura 3 (a), em princípio, não podem ser diferenciadas entre uma condição normal de operação ou uma condição de falha. Isto ocorre, especialmente, quando um baixo nível de carga é aplicado no eixo do motor. Entretanto, é importante destacar que esse vetor esconde uma série de informações relevantes. Por exemplo, as linhas indicadas na Figura 3 (b) fornecem uma informação adicional da direção de deslocamento dos descritores, o que permite resolver, por análise visual, situações semelhantes.

4.1 Caracterização da falha

O gráfico da Figura 4 ilustra o resultado do treinamento de uma rede SOFM com 12 neurônios distribuídos numa malha 3×4 . Cada neurônio treinado, ou protótipo, foi marcado no gráfico com um hexagrama. Os vetores de entrada utilizados no treinamento da rede são a entropia e energia das decomposições wavelet e a dimensão fractal do sinal de vibração. Os parâmetros do treinamento da rede foram ajustados para um número máximo de 100 épocas com taxa de aprendizagem inicial de 0,9, decaindo até 0,001. A vizinhança inicial tem valor igual à metade do número de neurônios da menor dimensão da malha de neurônios e termina com vizinhança 0, ou seja, apenas o neurônio vencedor é atualizado.

Depois de treinada, foram atribuídos aos protótipos os rótulos representado pelos círculos na Figura 5. Esses rótulos correspondem aos registros históricos de manutenção do equipamento. Para cada nova medição do sinal de vibração, o procedimento de extração de características é repetido e obtém-se um novo vetor de características \mathbf{k}_{novo} . Esse novo vetor é então identificado com o rótulo do protótipo da rede SOFM que satisfaz a expressão da Eq. 7. Como são realizadas várias amostragens do sinal de vibração, um conjunto de novos vetores é obtido. Verifica-se, então, qual

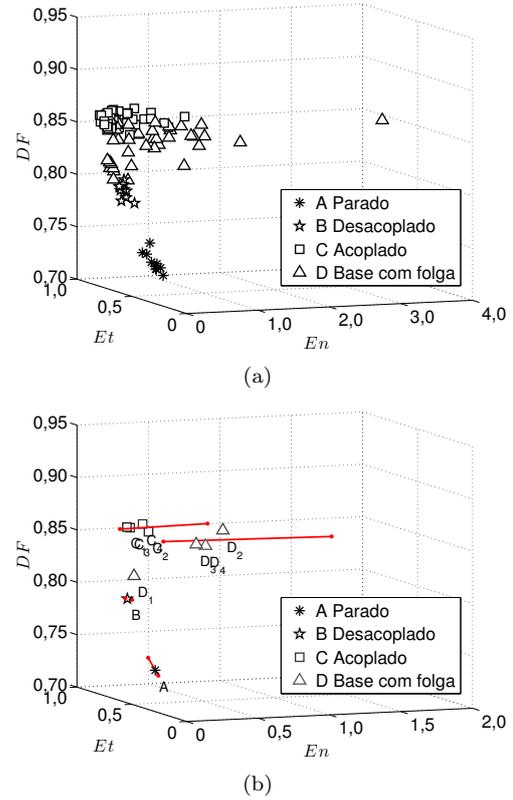


Figura 3: (a) Gráfico de espalhamento dos descritores En , Et e DF para diversas condições de operação e diferentes níveis de carga. (b) Representação gráfica da intensidade e deslocamento dos descritores, utilizando os valores médios das condições como referência.

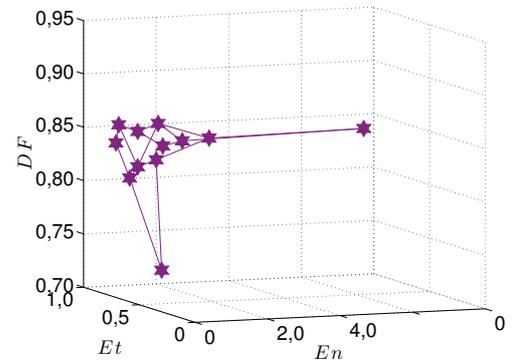


Figura 4: Protótipos não rotulados da rede SOFM no espaço dos descritores.

o rótulo da maioria dos vetores para determinar para qual tipo de condição o equipamento se aproxima e também que tipo de falha possivelmente está acontecendo ou prestes a acontecer.

Dessa forma, se o equipamento sofre alguma mudança na sua condição, é possível determinar qual o tipo de falha está associada a esse evento, como ilustrado na Figura 5 pelos marcadores vazados. Os vetores de características da nova condição são associados aos protótipos rotulados da SOFM utilizando o critério BMU e recebem seu

rótulo.

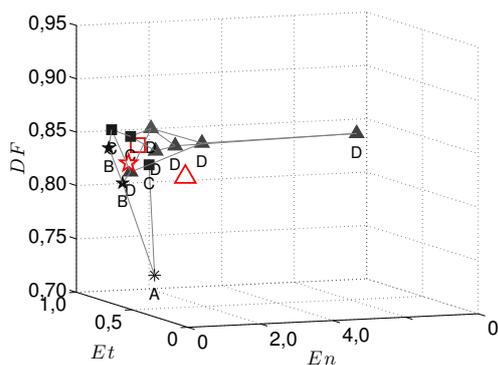


Figura 5: Vetores de características de condições desconhecidas (marcadores vazados) são identificados usando a rede SOFM rotulada conforme códigos da Tabela 1.

5 Conclusões

Neste trabalho apresenta uma metodologia para detecção de falhas em máquinas rotativas baseada em sinais de vibração obtidos com acelerômetros MEMS. A metodologia proposta é independente da análise espectral do sinal de vibração e não requer um banco de dados com informações prévias para comparação.

O monitoramento é feito a partir da observação do deslocamento dos agrupamentos no espaço de características, indicando as mudanças de condição do equipamento. A análise do deslocamento correlacionado com padrões históricos permite não apenas determinar mudanças de condição de operação de um equipamento como também inferir o provável motivo da falha.

Os resultados mostram que a metodologia proposta pode ser utilizada tanto para o monitoramento da condição de máquina quanto para a identificação das falhas. Os protótipos obtidos com uma rede SOFM, treinada com dados históricos, permitem a visualização dos deslocamentos no espaço de características e, também, a caracterização da falha.

Em trabalhos futuros pretende-se incorporar as informações de direção e intensidade no treinamento da rede SOFM. A investigação de novas métricas e a coleta de sinais de vibração em eixos simultâneos permitirá avaliar diversas condições de operação com falhas a fim de expandir as aplicações dessa metodologia. Espera-se que seja possível inferir a combinação de falhas que resultam em uma mudança de condição.

Agradecimentos

Este trabalho recebeu apoio financeiro do programa PROAPP/IFCE 02-2012.

Referências

- Chakraborty, K., De, A. and Chakrabarti, A. (2012). Voltage stability assessment in power network using self organizing feature map and radial basis function, *Computers and Electrical Engineering* **38**: 819–826.
- Chen, Y., Ni, J.-Q., Diehl, C. a., Heber, A. J., Bogan, B. W. and Chai, L.-L. (2010). Large Scale Application of Vibration Sensors for Fan Monitoring at Commercial Layer Hen Houses, *Sensors* **10**(12): 11590–11604.
- Hassan (2013). Current state of neural networks applications in power system monitoring and control, *Electrical Power and Energy Systems* **51**: 134–144.
- Jiang, D. and Liu, C. (2011). Machine condition classification using deterioration machine condition classification using deterioration feature extraction and anomaly determination, *IEEE Transactions on Reliability* **60**(1): 41–48.
- Kohonen, T. (2001). *Self-organizing Maps*, 3 edn, Springer.
- Konar, P. and Chattopadhyay, P. (2011). Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs), *Applied Soft Computing* **11**(6): 4203–4211.
- Li, B., Zhang, P.-L., Tian, H., Mi, S.-s., Liu, D.-s. and Ren, G.-q. (2011). A new feature extraction and selection scheme for hybrid fault diagnosis of gearbox, *Expert Systems with Applications* **38**(8): 10000–10009.
- Li, H., Zhang, Y. and Zheng, H. (2010). Application of hermitian wavelet to crack fault detection in gearbox., *Mechanical Systems and Signal Processing* **25**(4): 1353–1363.
- Mallat, S. (1999). *A wavelet tour of signal processing*, 2 edn, Academic Press.
- Maruthi, G. S. and Vittal, K. P. (2005). Electrical Fault Detection in Three Phase Squirrel Cage Induction Motor by Vibration Analysis using MEMS Accelerometer, *2005 International Conference on Power Electronics and Drives Systems* **2**: 838–843.
- Paiva, H. M., Galvão, R. K. H. and Rodrigues, L. (2009). A wavelet-based multivariable approach for fault detection in dynamic systems, *Revista Controle & Automação* **20**(4): 455–464.
- Ramalho, G. L. B., Schmidlin Jr, C. R., Bezerra, L. D. S. and Dias, S. V. (2012). Monitoramento de condição de máquina utilizando acelerômetro MEMS, *Revista Tecnologia (UNIFOR)* **33**(1).