

# Monitoramento de condição de máquina utilizando acelerômetro MEMS

## *Machine condition monitoring using MEMS accelerometer*

**Geraldo Luis Bezerra**

**Ramalho**

gramalho@ifce.edu.br  
Instituto Federal de Educação,  
Ciência e Tecnologia do Ceará  
– Campus Maracanaú

**Celso Rogério Schmidlin**

**Júnior**

celso@ifce.edu.br  
Instituto Federal de Educação,  
Ciência e Tecnologia do Ceará  
– Campus Maracanaú

**Luiz Daniel Santos Bezerra**

luizdaniel@ifce.edu.br  
Instituto Federal de Educação,  
Ciência e Tecnologia do Ceará  
– Campus Maracanaú

**Samuel Vieira Dias**

samueldias@ifce.edu.br  
Instituto Federal de Educação,  
Ciência e Tecnologia do Ceará  
– Campus Maracanaú

### 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. Os métodos de detecção precoce de falhas tradicionalmente empregam a Transformada de Fourier para realizar a análise espectral de sinais de vibração obtidos com acelerômetros piezoelétricos. Neste trabalho, propomos uma abordagem baseada em Transformada Wavelet e Dimensão Fractal para a extração de características de um sinal de vibração obtido com acelerômetros MEMS. A partir disso, são apresentados resultados obtidos em ensaios experimentais que comprovam a aplicabilidade da metodologia proposta.

**Palavras-chave:** Condição de máquina. Detecção de falhas. Acelerômetro MEMS.

### 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 wavelet Transform and Fractal Dimension for extracting features of a vibration signal obtained with MEMS accelerometers. This paper presents results from experimental studies that demonstrate the applicability of the proposed methodology.

**Keywords:** Machine condition. Fault detection. MEMS accelerometer.

## 1 Introdução

O monitoramento de condição de máquina surgiu na década de 1970 como uma forma de atuar sistematicamente com base na modificação de parâmetros de condição ou desempenho. Na manutenção preditiva, é desejável que os equipamentos sejam constantemente monitorados, de modo que seja possível detectar precocemente possíveis falhas. Conforme afirmam Kardec e Nascif (2001), a detecção precoce de falhas ajuda a prevenir quebras e interrupções não programadas da linha produção.

A Figura 1 ilustra o desempenho de uma máquina ao longo de sua vida útil. Quando as condições operacionais da máquina começam a mudar, o primeiro efeito é a perda de desempenho, seguida por um aumento da vibração. Se nenhuma ação for tomada, em geral porque a máquina não é monitorada preditivamente, ocorrerá o aumento de ruído e a máquina terá seu desempenho reduzido significativamente. Em algum ponto entre o início da vibração e antes da geração de calor excessivo, a intervenção para manutenção será pequena. Se o desempenho cai abaixo do nível de alarme, os custos de manutenção crescem exponencialmente.



Fonte: Adaptado de National Instruments (2011).

**Figura 1:** Sinais de alarme de uma máquina sujeita a falhas.

Existem diferentes métodos para monitorar equipamentos industriais em modo periódico ou contínuo (*on-line*). Alguns deles utilizam para análise de parâmetros o nível e a viscosidade de lubrificantes, temperatura, ruído e vibração (Nepomuceno, 1989). A análise espectral do sinal de vibração do equipamento monitorado é uma metodologia de particular interesse, porque é um método não invasivo. Ela emprega a análise por Transformada de Fourier (TF) para obter o espectro de frequência de sinais de vibração obtidos com transdutores de vibração, em geral, acelerômetros piezelétricos fixados na máquina monitorada. O espectro é analisado a partir de comparações com espectros previamente conhecidos.

Sensores piezelétricos possuem uma larga banda de frequência e podem ser utilizados para medir vibrações com frequências da ordem de poucos hertz até algumas dezenas de quilohertz. Defeitos de rolamento em máquinas rotativas geralmente causam harmônicos da ordem de quilohertz, dependendo das características dos rolamentos e da velocidade de rotação do motor. Existem modelos matemáticos para descrever diversos tipos de falhas de rolamentos, por isso, muitos estudos revelam particular interesse nessa área de pesquisa.

Trabalhos recentes têm investigado o uso de acelerômetros MEMS (*microelectromechanical system*) em substituição aos acelerômetros piezoelétricos. Sensores MEMS são aplicados desde detecção de falhas em automóveis (Rebello *et al.*, 2010) até monitoramento de ventiladores (Chen *et al.*, 2010). No trabalho de Maruthi e Vittal (2005), foram utilizados acelerômetros MEMS em substituição aos tradicionais acelerômetros piezelétricos no monitoramento de falhas em motores monofásicos gaiola de esquilo. Os autores realizaram uma análise espectral de falhas a partir do sinal do acelerômetro MEMS e através da assinatura de corrente do motor. O trabalho mostra que a análise do sinal de vibração adquirido com um sensor MEMS pode ser utilizado para detectar falhas mecânicas no estator e no rotor, dentre elas, folgas e desalinhamento.

A obtenção da TF de um sinal discreto pode ser conseguida com o algoritmo da Transformada Rápida de Fourier – FFT, do inglês *Fast Fourier Transform* – (Oppenheim; Schafer, 2010), largamente utilizado e disponível em sistemas computacionais e processadores de sinais. Contudo, a investigação de métodos diferentes de análise e processamento do sinal de vibração toma espaço nos trabalhos científicos mais recentes. Em Paiva, Galvão e Rodrigues (2009), foi utilizada a Transformada *Wavelet* (TW) na filtragem do sinal, com o objetivo de detecção de falhas em sistemas dinâmicos. A TW foi utilizada para identificar modelos das sub-bandas do comportamento normal do sistema monitorado.

Em Li, B. *et al.* (2011), foi proposto um esquema de extração e seleção de características baseado em *wavelets* visando a detecção de falhas em caixas de engrenagens. Konar e Chattopadhyay (2011) empregaram o uso de extração

de características do sinal de vibração baseado em transformada *wavelet*. Os autores utilizaram um equipamento de testes para coletar sinais de vibração obtidos com um sensor piezolétrico. A partir das decomposições *wavelet*, foram extraídas medidas, as quais, posteriormente, foram classificadas utilizando uma máquina de vetor de suporte (SVM). No trabalho de Jiang e Liu (2011), é investigado o monitoramento de condição de máquina através da extração de características que indiquem a deterioração do equipamento. Li *et al.* (2010) obtiveram êxito na detecção de falhas em caixas de engrenagens utilizando uma *wavelet* hermetiana.

Os trabalhos citados apresentam alternativas para a coleta do sinal de vibração obtido com acelerômetros piezolétricos, que são muito caros, e alternativas à análise espectral através da TF, que exige o uso de processadores de sinais (Choi *et al.*, 2011). 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 piezolétricos. Por causa de limitações dos sensores MEMS, a metodologia proposta busca encontrar defeitos mecânicos que possam ser caracterizados em baixas frequências.


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 TW através de um algoritmo computacionalmente simples, que pode ser implementado em microcontroladores. Os resultados preliminares mostram que defeitos como folgas de acoplamento ou de fixação e subtenção são passíveis de serem caracterizados com a metodologia proposta. A metodologia empregada neste trabalho foi patenteada no Instituto Nacional de Propriedade Industrial (INPI) e se encontra atualmente em sigilo sob o protocolo 221106543933.

Este trabalho está organizado da seguinte forma. Na seção 2, apresentamos a metodologia de extração de características do sinal de vibração através de métricas obtidas sobre as decomposições da TW e o cálculo da dimensão fractal (DF). Na seção 3, apresentamos o equipamento utilizado nos ensaios e os detalhes sobre a coleta de dados. Os resultados e discussões são apresentados na seção 4. As conclusões e sugestões de trabalhos futuros são apresentados na seção 5.

## 2 Metodologia

O uso de sinais de vibração obtidos com acelerômetros MEMS requer alguns cuidados especiais (Albarbar *et al.*, 2008; Albarbar *et al.*, 2009). Os acelerômetros MEMS mais simples possuem limitação em banda de frequência e, em geral, fornecem um sinal distorcido, com harmônicas fantasmas, por causa do fenômeno *aliasing* (Oppenheim; Schaffer, 2010). Esse problema é intensificado quando o sinal é medido em um equipamento acionado por conversores eletrônicos de frequência. Os conversores possuem um sistema eletrônico de chaveamento que induz o ruído eletromagnético de elevada frequência, o que aumenta a chance de se obter um sinal ruidoso do sensor.

Nesta seção, é apresentado um método alternativo à análise espectral do sinal de vibração, que é geralmente baseada na TF. O método proposto, ilustrado na Figura 2, utiliza descritores que medem o grau de complexidade do sinal de vibração. Esses descritores se baseiam em métricas extraídas diretamente do sinal por meio da dimensão fractal (Falconer, 2003), e em métricas extraídas dos primeiros níveis de decomposição *wavelet* do sinal de vibração obtido com acelerômetros MEMS.



**Figura 2:** Metodologia de caracterização da condição de falha.

## 2.1 Transformada Wavelet

A Transformada de Fourier (TF) é um recurso matemático muito empregado na análise de sinais. No domínio discreto, emprega-se a Transformada de Fourier Discreta (TFD), a qual possui um algoritmo computacional bastante conhecido, chamado FFT – *Fast Fourier Transform* (Oppenheim; Schaffer, 2010). O algoritmo FFT pode ser encontrado facilmente em diversas ferramentas computacionais de simulação, osciloscópios digitais e processadores digitais de sinais (DSP, do inglês *Digital Signal Processor*).

Neste trabalho, foi utilizada uma Transformada *Wavelet* Discreta (TWD) 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 ele pode ser decomposto em diversos níveis de aproximação e detalhes.

Esse método não substitui a análise espectral obtida com a FFT, mas oferece uma alternativa viável para análise das características contidas no sinal. Além disso, o algoritmo utilizado para cálculo da TWD pode ser implementado em microcontroladores simples, sem a necessidade de uso de DSP.


Considere  $x$  um sinal unidimensional periódico discreto que representa o sinal de vibração obtido com um acelerômetro MEMS a uma taxa de amostragem  $SR$  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:

$$a1[i] = (x[2(i - 1) + 1] + x[2i])/2 \quad e \quad (1)$$

$$d1[i] = x[2(i - 1) + 1] - x[2i], \quad (2)$$

Em que,  $i = 1, 2, \dots, N/2$ , sendo  $N$  o número de amostras do sinal. As decomposições seguintes utilizam as Equações 1 e 2, calculadas sobre a componente de aproximação do nível anterior. O processo se repete para o nível seguinte até que seja atingido um critério de parada. A Equação 1 pode ser vista como um filtro passa baixa, enquanto a 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. Isso significa que, para cada nível de decomposição, são obtidos detalhes em diferentes escalas. A Figura 3 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 3:** Esquema de decomposição *wavelet* em sucessivos componentes de aproximação ( $a_j$ ) e componentes de detalhes ( $d_j$ ).

## 2.2 Métricas para caracterização do sinal

Um sinal de vibração é uma composição de diversas frequências e apresenta um padrão estocástico bastante complexo. Essa 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 das equações num esquema como o ilustrado na Figura 2. 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 dela. A partir dessas suposições, é possível definir métricas para as decomposições do sinal a fim de obter quatro descritores para o sinal original.

*RMS*: valor médio quadrático é uma medida obtida a partir do primeiro nível de aproximação do sinal ( $a_1$ ). O descritor *RMS* é definido como o valor médio ou nível DC do sinal discreto  $a_j$ , de dimensão  $D$ , através da seguinte expressão:

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

*J*: a taxa de variação da aceleração (*Jerk*) é uma medida obtida a partir do primeiro nível de detalhes do sinal ( $d_1$ ). O descritor *J* fornece o médio quadrático do sinal discreto  $d_j$ , de dimensão  $D$ , através da seguinte expressão:

$$J = \frac{1}{D} \sum_{i=1}^D d_j[i]^2 \quad (4)$$

*Et*: a entropia do sinal mede o grau de complexidade do sinal de vibração levando em consideração a quantidade de informação necessária para representá-lo. A entropia é obtida a partir da densidade de probabilidade  $p$  do coeficiente  $d_j$ , por meio da seguinte expressão:

$$Et = -10 \log p[d_j]. \quad (5)$$

*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 (*FD*) de um sinal é determinado pela seguinte expressão:

$$FD = \frac{\log N}{\log R} \quad (6)$$

Em que  $N$  é o número de caixas (*boxes*)  $\delta$  – 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.


### 3 Modelo experimental

#### 3.1 Sistema de aquisição de dados

A medição da vibração foi realizada com um acelerômetro MEMS triaxial (Freescale MMA7361). O sensor possui banda de frequência pequena, 400Hz, faixa de medição  $\pm 1,5$  g ( $\pm 1,6$  V) 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  $\pm 5\%$ .

A aquisição do sinal de vibração foi obtida 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 testes foram realizados em uma bancada de ensaios, como mostrado na Figura 4 e detalhado na Tabela 1. O sensor foi parafusado à carcaça do motor monitorado para medir a vibração eixo no sentido radial vertical, indicado na imagem pelo sistema de coordenadas  $+x$ . Para os ensaios realizados neste trabalho, as medições nas direções  $-y$  (radial horizontal) e  $+z$  (axial) não foram tomadas.



**Figura 4:** Posicionamento e orientação do sensor no equipamento monitorado. Bancada de testes do Laboratório de Acionamento de Máquinas e Eletrônica de Potência (LAMEP) – IFCE – Campus Maracanaú.

Tabela 1 – Parâmetros da bancada de ensaios

Elemento	Descrição
Motor	Motor de indução trifásico com rotor em gaiola WEG, 1,5 cv, 220 V (ligação em Y), 4,31 A, 60 Hz (1700 rpm).
Acionamento	Conversor de frequência de WEG CFW09 de 1,5 cv. Frequência de comutação de 5kHz.
Simulador de carga	Freio eletrodinâmico com acionamento manual, equipado com dinamômetro com escala de 0 a 100 N.
Estrutura	Base em chapa de aço e trilho aparafusado, apoiada sobre rodízios de vinil com travas. Acoplamento direto com amortecimento de borracha entre eixos de motor e disco.

### 3.2 Processamento dos sinais

Foi desenvolvido um *script* no programa MATLAB, responsável pela leitura *on-line* do coletor de dados, processamento do sinal e exibição dos gráficos. O *script* utiliza as Equações 1 e 2 para calcular 4 níveis de decomposições *wavelet* Haar do sinal de vibração. Os valores de energia (*RMS*) e entropia (*Et*) do sinal são obtidos com as Equações 3 e 5 aplicadas sobre os coeficientes de detalhes da 2ª e 3ª decomposições *wavelet* do sinal de vibração. O cálculo da taxa de variação da aceleração (*J*) é obtido com a Equação 4 aplicada sobre o primeiro nível de detalhes da decomposição *wavelet*. O cálculo da dimensão fractal (*FD*) através da Equação 6 foi obtido a partir do sinal formado com os coeficientes de detalhes. O tempo médio de processamento do *script* para cada medição foi de 0,2 segundos em um computador de dois núcleos a 2,66 GHz.

## 4 Resultados e discussão

Foram realizados três ensaios diferentes: dois com a bancada de testes e outro com um motor a vazio e acionamento direto da rede. Cada ensaio foi composto pela coleta de 10 medições do sinal de vibração, com o motor em estado permanente e em condição de operação determinada por parâmetros como velocidade de rotação, intensidade de carga e existência ou não de uma falha mecânica ou elétrica. Os dados foram processados e exibidos em gráficos na tela de um computador, utilizando *scripts* desenvolvidos no programa MATLAB.

### 4.1 Ensaio 1

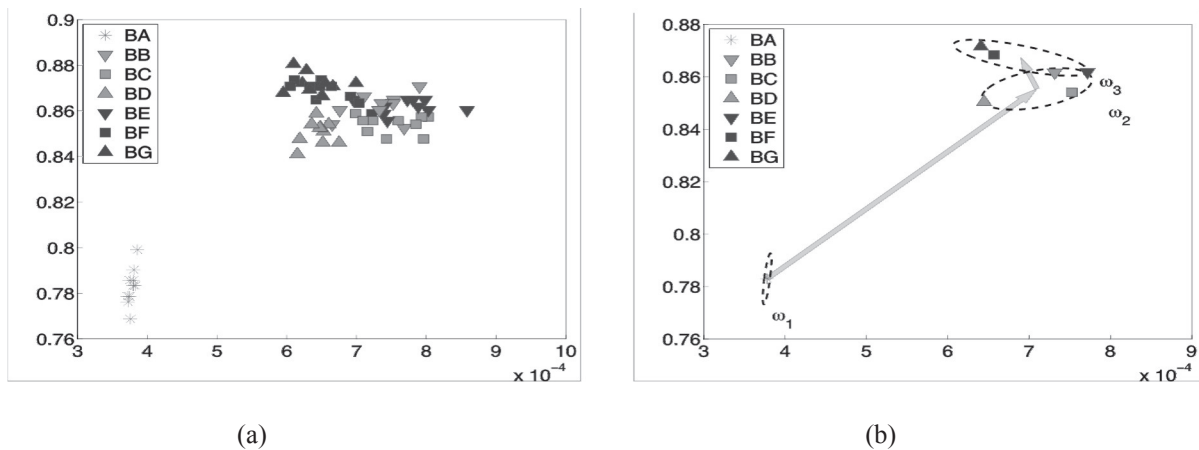
O primeiro ensaio foi realizado com falhas mecânicas introduzidas no equipamento da bancada de testes. Dois tipos de falhas mecânicas foram simulados: i) folga no acoplamento entre eixo do motor e carga, simulando uma condição de deterioração do elemento de amortecimento; ii) folga na fixação da base do motor, simulando uma condição de má

fixação do motor. Para efeito de referência, também foram realizadas medições do motor em estado de repouso. As falhas mecânicas foram acrescentadas no intervalo entre duas medições consecutivas. Cada código de duas letras apresentado na Tabela 2 representa uma falha inserida no equipamento de forma isolada, com diferentes níveis de carga. O torque e a velocidade de rotação para cada condição estão indicados na tabela.

Tabela 2 – Parâmetros do ensaio 1

Condição de operação (Classe)	Código	Estado de operação do motor	Velocidade	Torque
			rpm	N.m
$\omega_1$	BA	motor em repouso	–	–
	BB		1782	1,7
$\omega_2$	BC	folga no acoplamento da carga ao eixo do motor	1763	3,3
	BD		1744	5,0
$\omega_3$	BE	folga na fixação da base do motor	1782	1,7
	BF		1763	3,3
	BG		1744	5,0

Os dados coletados são mostrados no gráfico da Figura 5-a. No condição de repouso ( $\omega_1$   $\omega_1$ ), representado pelo marcador BA, é possível observar pouca dispersão no valor do descritor da taxa de variação da aceleração ( $J$ ) e uma dispersão significativa para o descritor dimensão fractal ( $DF$ ). Isso está coerente com o fato de que, mesmo em repouso, existe um ruído associado à coleta do sinal de vibração do acelerômetro que apresentará um padrão aleatório bastante complexo. Percebe-se que as demais condições de operação estão significativamente afastadas da condição de repouso, já que a amplitude do sinal do acelerômetro aumenta conforme o motor gira.



- (a) Dispersão das medidas de cada condição de máquina.
- (b) Valores médios das medidas delimitados em classes estatísticas. As setas indicam a direção de mudança de condição durante o ensaio.

**Figura 5:** Gráfico de espalhamento dos descritores dos dados coletados no ensaio 2.

O gráfico da Figura 5-b exibe o valor médio das 10 medidas obtidas em cada condição de operação para níveis de carga diferentes. As médias das medidas estão indicadas dentro de classes de dispersão estatística, representada por uma elipse pontilhada. O aumento da amplitude de vibração acarreta um aumento nos valores do sinal e afeta diretamente o descritor  $DF$ . A presença de diversos componentes de frequências de vibração decorrente da falha mecânica aumenta a intensidade medida pelo descritor  $J$ .

Para as condições  $\omega_2$  e  $\omega_3$ , a presença de folga mecânica exerce uma influência direta na variação dos descritores  $J$  e  $DF$ . Isso corresponde ao maior grau de complexidade do sinal de vibração medido pelo sensor, já que uma folga no acoplamento ou na fixação do motor pode inserir diversas frequências causadas pela vibração transmitida diretamente para o eixo. O menor valor de  $J$  para cargas mais elevadas ocorre porque algumas frequências de vibração são atenuadas com o aumento da carga.


### 4.2 Ensaio 2

Neste ensaio, realizado com o equipamento da bancada de testes, foi verificado o comportamento do equipamento para diferentes níveis de carga em duas condições de falha. Cada medição foi identificada com os códigos apresentados na Tabela 3. Os resultados foram separados em duas classes, indicando funcionamento normal sem carga e funcionamento em falha com carga.

**Tabela 3** – Parâmetros do ensaio 2

Condição de operação (Classe)	Código	Estado de operação do motor	Velocidade	Torque
			rpm	N.m
$\Omega_1$	CA	motor sem carga	1797	–
	CE		1797	–
$\Omega_2$	CB	folga no acoplamento do eixo do motor	1782	1,7
	CC		1763	3,3
	CD		1744	5,0
	CF		1782	1,7
$\Omega_3$	CG	folga na fixação do motor	1763	3,3
	CH		1744	5,0

Os dados obtidos neste ensaio são exibidos na Figura 6-a. Os tons dos marcadores indicam tipos diferentes de falhas. A Figura 6-b destaca as duas condições de operação: normal ( $\Omega_1$ ) e em falha ( $\Omega_2$ ). Definindo-se limiares para o valor  $RMS$  e para o valor  $J$ , é possível determinar de forma automática em que condição de operação se encontra o equipamento. Por exemplo, para  $RMS > 0,31$  e  $j < 7 \times 10^{-5}$ , pode-se concluir que o equipamento opera em condição de falha, com folga no acoplamento do eixo do motor. De forma similar, se  $j > 7 \times 10^{-5}$ , está caracterizada uma folga na fixação do motor. Nesse experimento, a falha identificada como CB não pode ser diferenciada de uma condição normal de operação. Isso ocorre devido ao baixo nível de carga aplicado no eixo do motor. Tal experimento comprova a viabilidade do método para detecção de falhas mecânicas quando o equipamento é submetido a uma carga.



(a) Gráfico de espalhamento dos descritores  $RMS$  e  $J$ .  
 (b) Condições de operação normal  $\Omega_1$  (sem carga) e em falha  $\Omega_2$  (com carga). A seta representa a direção da mudança de condição.

**Figura 6:** Simulação de monitoramento de condição.



### 4.3 Ensaio 3

A fim de verificar a aplicabilidade do método no monitoramento de falhas elétricas, foi realizado um ensaio de subtensão com motor a vazio. Um motor de indução trifásico com rotor em gaiola WEG, 1,5 cv, 220 V (ligação em  $\Delta$ ), 4,42 A, 60 Hz (1715 rpm) foi acionado com partida direta e depois foi realizada uma simulação de uma falta de fase.

A Figura 7 exibe os resultados das medições em operação normal (DA) e em subtensão (DB). Existe uma diferença significativa nos valores do descritor  $J$  e do descritor  $RMS$  para as duas condições, o que torna possível a detecção dos dois eventos a partir da definição de limiares simples. A falta de fase provoca um desbalanceamento eletromagnético no motor que o faz vibrar mais intensamente e, conseqüentemente, aumenta a taxa de variação da velocidade, assim como o nível DC do sinal de vibração. Esse método pode ser adotado complementarmente em sistemas convencionais de detecção de subtensão em caso de falha dos dispositivos de proteção.




Figura 7: Medições para a simulação de subtensão.

## 5 Conclusão

Neste trabalho, foi apresentada uma metodologia para monitoramento da condição de operação de máquina 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.

Quatro descritores do sinal são propostos, utilizando-se os coeficientes de detalhes de decomposições *wavelet* e dimensão fractal. Os resultados experimentais mostram que diferentes condições de operação de um equipamento rotativo podem ser identificadas através de análise gráfica, observando-se os agrupamentos representados no espaço de descritores.

A metodologia proposta pode ser utilizada para o monitoramento da condição de máquina, de forma que o registro do deslocamento dos agrupamentos no espaço de características indique as mudanças de condição do equipamento. A análise desse registro permite determinar mudanças de condição de operação de um equipamento mecânico, ou em motores e transformadores, causadas por interferências no campo eletromagnético.

A utilização de novas métricas e a coleta de sinais de vibração em eixos simultâneos permitirão aprofundar a investigação dos resultados obtidos em diversas condições de operação com falhas. Também será investigado, em trabalhos futuros, um método automático de classificação não supervisionada, a fim de viabilizar o desenvolvimento de um sistema *on-line* de monitoramento de condição.

## Agradecimentos

Este trabalho recebeu apoio financeiro do programa PROAPP/IFCE 01/2010.

## Referências

- ALBARBAR, A. et al. Performance evaluation of MEMS accelerometers. *Measurement*, v. 42, n. 5, p. 790-795, 2009.
- ALBARBAR, A. et al. Suitability of MEMS accelerometers for condition monitoring: an experimental study. *Sensors*, v. 8, n. 2, p. 784-799, 2008.
- BADRI, A. E.; SINHA, J. K.; ALBARBAR, A. A typical filter design to improve the measured signals from MEMS accelerometer. *Measurement*, v. 43, n. 10, p. 1425-1430, 2010.
- CHEN, Y. et al. Large scale application of vibration sensors for fan monitoring at commercial layer hen houses. *Sensors*, v. 10, n. 12, p. 11590-11604, 2010.
- CHOI, S. et al. Implementation of a fault-diagnosis algorithm for induction machines based on advanced DSP techniques. *IEEE Transactions on Industrial Electronics*, v. 58, n. 3, p. 937-948, 2011.
- FALCONER, K. *Fractal geometry: mathematical foundations and applications*. 2nd ed. Chichester: Wiley, 2003.
- JIANG, D.; LIU, C. Machine condition classification using deterioration feature extraction and anomaly determination. *IEEE Transactions on Reliability*, v. 60, n. 1, p. 41-48, 2011.
- KARDEC, A.; NASCIF, J. *Manutenção: função estratégica*. 2<sup>nd</sup> ed. Rio de Janeiro: Qualitmark, 2001.
- KONAR, P.; CHATTOPADHYAY, P. Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs). *Applied Soft Computing*, v. 11, n. 6, p. 4203-4211, 2011.
- LI, B. et al. A new feature extraction and selection scheme for hybrid fault diagnosis of gearbox. *Expert Systems with Applications*, v. 38, n. 8, p. 10000-10009, 2011.
- LI, H.; ZHANG, Y.; ZHENG, H. Application of Hermitian wavelet to crack fault detection in gearbox. *Mechanical Systems and Signal Processing*, v. 25, n. 4, p. 1353-1363, 2010.
- MALLAT, S. *A wavelet tour of signal processing*. 2nd ed. San Diego: Academic Press, 1999.
- MARUTHI, G. S.; VITTAL, K. P. Electrical fault detection in three phase squirrel cage induction motor by vibration analysis using MEMS accelerometer. *IEEE International Conference on Power Electronics and Drives Systems*, v. 2, p. 838-843, 2005.
- NATIONAL INSTRUMENTS. Biblioteca Técnica para Monitoramento de Condição de Máquina. Disponível em: <<http://zone.ni.com/devzone/cda/tut/p/id/13482>>. Acesso em: 20 maio 2011.
- NEPOMUCENO, L. X. *Técnicas de Manutenção Preditiva*. São Paulo: Edgard Blucher, 1989.
- OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-time signal processing*. 3rd ed. New Jersey: Prentice Hall, 2010.
- PAIVA, H.; GALVÃO, R.; RODRIGUES, L. A wavelet-based multivariable approach for fault detection in dynamic systems. *Revista Controle & Automação*, Campinas, SP, v. 20, n. 4, p. 455-464, Nov. 2009.
- RAO, S. *Vibrações mecânicas*. 4th ed. São Paulo: Prentice Hall, 2008.
- REBELLO, J.; CLEGHORN, W. L.; MILLS, J. K. Design and analysis of a low frequency MEMS vibration sensor for automotive fault detection. *International Journal of Vehicle Design*, v. 54, n. 2, p. 93-110, 2010.