

**Código do Trabalho: 56112**

## **UTILIZAÇÃO DE REDES NEURAIS NA IDENTIFICAÇÃO DE FALHAS EM ROLAMENTOS A PARTIR DE PARÂMETROS ESTATÍSTICOS.**

**Roberto de Araújo Bezerra**

UNICAMP / Faculdade de Engenharia Mecânica - UFC/ Ceará  
Caixa Postal 6051 – Campinas –SP – CEP: 13083-970- [roberto@fem.unicamp.br](mailto:roberto@fem.unicamp.br) –  
[bezerra\\_roberto@yahoo.com.br](mailto:bezerra_roberto@yahoo.com.br)

**Darley Fiácro de Arruda Santiago**

UNICAMP / Faculdade de Engenharia Mecânica - CEFET/ Piauí  
Caixa Postal 6051 – Campinas –SP – CEP: 13083-970 - [darley@fem.unicamp.br](mailto:darley@fem.unicamp.br)

**Robson Pederiva**

UNICAMP / Faculdade de Engenharia Mecânica  
Caixa Postal 6051 – Campinas –SP – CEP: 13083-970- [robson@fem.unicamp.br](mailto:robson@fem.unicamp.br)

### **Resumo**

*Na manutenção, preditiva a determinação das falhas em seu estágio inicial é um pré-requisito indispensável para as técnicas utilizadas. Nos rolamentos, a presença de falhas podem ser indicadas em sua fase inicial através de técnicas de análise vibratória no domínio do tempo e da frequência. No domínio da frequência, existem diversas técnicas que podem, não só indicar a presença de falhas em um rolamento como possibilitam identificar qual o tipo da falha. Porém, em sua maioria, estas técnicas exigem conhecimento técnico para o correto diagnóstico da falha. Por outro lado, as técnicas no domínio do tempo, que utilizam parâmetros estatísticos, podem em alguns casos indicar a presença de falhas, porém não conseguem determinar qual o tipo da falha. A partir de rolamentos com falhas induzidas na pista externa, pista interna e esfera, serão aplicadas diversas técnicas no domínio do tempo. Os parâmetros serão usados como entrada de uma Rede Neural, com o objetivo de estabelecer um critério rápido e confiável para o diagnóstico de falhas em rolamentos.*

**Palavras-chave:** Diagnóstico de falhas, Redes Neurais, Falhas em Rolamentos, Manutenção Preditiva.

## **1. INTRODUÇÃO**

Pela redução de custo e diminuição no tempo de reparo, a manutenção preditiva tem se tornado uma eficiente estratégia para indústria moderna (Tse, et. al., 2001). A identificação de falhas em seu estágio inicial possibilita a intervenção na máquina antes que haja uma propagação, que resulte em comprometimento de outros componentes do sistema, o que justifica a busca de técnicas que possibilitem o diagnóstico de forma rápida e confiável. A manutenção preditiva utiliza um conjunto de técnicas que podem ser classificados como: medidas de Vibração e Acústica,

medidas de Temperatura, e Análise de Desgaste (*N. Tandon & A. Choudhury, 1999*). Em geral, as técnicas podem ser utilizadas em conjunto possibilitando um diagnóstico mais confiável.

As técnicas que utilizam medidas de vibração são largamente utilizadas e podem ser classificadas em três grupos de acordo com o domínio em que o sinal é tratado. Têm-se os métodos no domínio do tempo, métodos no domínio da frequência e os métodos no domínio tempo-frequência que são os mais recentes.

Os métodos no domínio do tempo são os mais simples. Destes métodos os mais difundidos são Nível Global RMS e Fator de Crista. Além destes, são usados os momentos de primeira, segunda, terceira e quarta ordem, que são conhecidos como Média, Variância, Assimetria e Curtose, sendo os dois últimos normalizados em relação ao desvio padrão. Estes métodos são, em geral, qualitativos, ou seja, podem, em alguns casos, indicar a presença de falha, porém não permitem a identificação do tipo da falha.

Neste trabalho, será desenvolvida uma rede neural que possibilita a identificação de falhas em rolamento de forma rápida e precisa. Os parâmetros de entrada foram escolhidos entre os diversos parâmetros estatísticos utilizados no domínio do tempo. Para realização deste trabalho, foram utilizados 12 rolamentos de esferas dos quais, 9 com falhas induzidas. Os ensaios para aquisição de dados foram realizados em uma bancada de ensaios.

## 2. TÉCNICAS DE IDENTIFICAÇÃO DE FALHAS EM ROLAMENTOS POR MONITORAMENTO DE VIBRAÇÃO NO DOMÍNIO DO TEMPO.

Os métodos no domínio do tempo Nível Global RMS e Fator de Crista são os mais simples, sendo este último a razão do valor de pico pelo valor do RMS. O fator de crista para rolamentos sem defeito tem valores entre 2 e 6. Com o surgimento de uma pequena falha no rolamento, o valor de pico sofre uma elevação maior que o RMS, logo o fator de crista atingirá valores maiores que 6. Além disso, este fator só é válido quando a única fonte de vibração é o rolamento (Silva, 1999). São obtidos pelas Equações (01) e (02).

$$RMS = \sqrt{\frac{1}{n} \sum_{k=1}^n x_k^2} \quad (01)$$

$$Fator\ de\ Crista = \frac{Pico_{max}}{RMS} \quad (02)$$

A Variância, Assimetria ou “Skewness” e Curtose são parâmetros estatísticos que podem ser usados com o objetivo de auxiliar a detecção de falhas em rolamentos. Nos rolamentos sem falha, a densidade de probabilidade do sinal de aceleração de um rolamento tem uma distribuição Gaussiana, logo o valor de assimetria tende a 0 e o valor de curtose tende a 3 (Martin, H. R., Honarvar, F., 1995). Com o surgimento de uma falha, no rolamento, o valor de curtose aumenta. Mas, à medida que a falha se espalha pela superfície da pista ou esfera o valor de curtose diminui podendo atingir valores menores que três mascarando uma possível falha no rolamento. A Variância, Assimetria e Curtose são obtidas pelas Equações (03), (04) e (05).

$$Variância = S^2 = \frac{\sum_{i=1}^N (x_i - m)^2}{N} \quad (03)$$

$$Assimetria = g_3 = \frac{M_3}{S^3} \quad (04)$$

$$\text{Curtose} = g_4 = \frac{M_4}{S^4} \quad (05)$$

Um fato bastante interessante relativo, aos parâmetros estatísticos, é que os momentos estatísticos ímpares dão informações sobre a posição do pico da densidade de probabilidade em relação ao valor médio, enquanto os parâmetros relacionados a valores pares indicam a expansão ou achatamento da distribuição, além disso, estes valores independem da velocidade e carga impostas ao rolamento. Para uma perfeita distribuição normal, os momentos ímpares tendem a zero e os momentos pares têm valores finitos (Martin, H. R., Honarvar, F., 1995). Um outro parâmetro estatístico que pode ser usado com o objetivo de fornecer informações sobre o estado do rolamento é o momento central de sexta ordem, Equação (06), (Samanta, B. and Al-Blalushi K. R., 2001).

$$\text{Momento central de sexta ordem} = g_6 = \frac{M_6}{S^6} \quad (06)$$

Além dos fatores acima foi usado o fator K (Silva, 1999), equação (07).

$$\text{Fator } K = \text{RMS} \times g_4 \quad (07)$$

onde :


$$\text{Momento de ordem } (t) = M_t = \frac{1}{N} \sum_{i=1}^N (X_i - m)^t \quad (08)$$

$\sigma$  = Desvio Padrão

Em função das características dos diversos parâmetros estatísticos, os mesmos foram usados neste trabalho como parâmetros de entradas de uma rede neural, a fim de identificar a presença e tipo de falha em um rolamento.

## 2. TESTES EXPERIMENTAIS

Os ensaios para aquisição de dados foram realizados em uma bancada de ensaios, Figura (01). Na obtenção dos dados, durante a fase de ensaios, um acelerômetro foi colocado na direção radial de maior carga.



**Figura 1.** Esquema da bancada usada

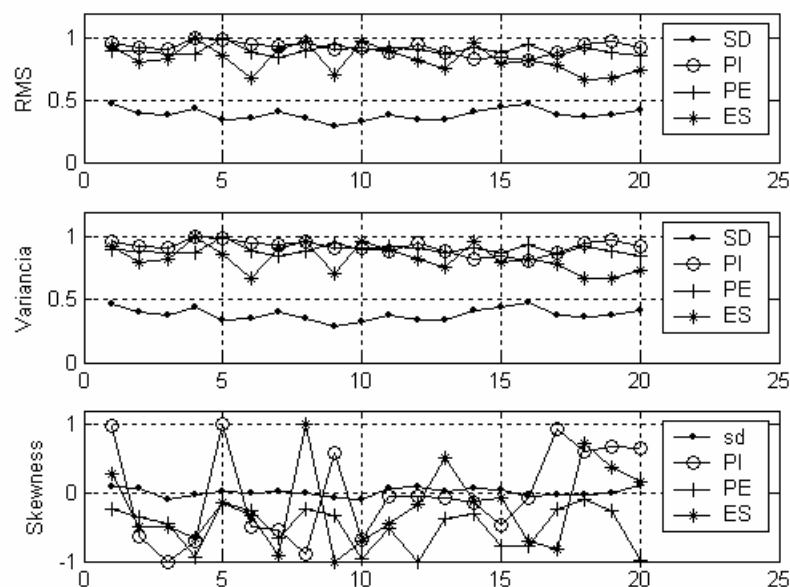
Os rolamentos foram montados na bancada com suas falhas na direção do acelerômetro. Desta forma, os defeitos eram detectados pelo acelerômetro e enviados para o analisador de sinais do Pulse da Bruel&Kjaer. Para cada ensaio, foram obtidos 16484 pontos com um tempo total de 1s. Durante os ensaios dos rolamentos, a pista interna foi mantida parada enquanto a pista externa girava a  $4800rpm$  ( $80Hz$ ). Durante a fase de tratamento dos dados, foi usado um filtro passa alta com frequência de corte de 2 kHz.

Foram usados 12 rolamentos, sendo, 3 sem defeitos, 3 com falha na pista interna, 3 com falha na pista externa e 3 com falha na esfera. As falhas presentes nos rolamentos foram induzidas, Figura (2). Todos os rolamentos tinham as mesmas dimensões: ângulo de pressão  $b=0^\circ$ , diâmetro da esfera  $d=7.144mm$ , diâmetro principal  $D=42,47mm$  e número de esfera  $n= 10$ .




**Figura 2.** Falhas induzidas nas pistas e esfera do rolamento

Para cada tipo de rolamento foram obtidos 20 ensaios, ou seja, 20 aquisições do tipo sem defeito, 20 para defeitos na pista interna, 20 para defeitos na pista externa e 20 para defeitos na esfera. Com o banco de dados em mãos, foram calculados os diversos parâmetros estatísticos: RMS, variância, assimetria (Skewness), curtose, momentos de sexta ordem e o fator K. Em seguida, os dados dos rolamentos com defeito foram normalizados. No processo de normalização de cada tipo de parâmetro, foi escolhido o maior valor, e os demais valores deste parâmetro foram divididos pelo valor escolhido, obtendo-se valores que variam entre 0 e 1. Somente para o parâmetro de assimetria, foram considerados os valores negativos e positivos obtendo-se valores que variavam entre -1 e 1. Em seguida, os dados foram dispostos em gráficos como mostrados nas Figuras (3) e (4).



**Figura 3.** RMS, Variância e Assimetria , sd = sem defeito, PI= defeito na pista Interna, PE= defeito. na pista Externa e ES= defeito. na Esfera



**Figura 4.** Curtose, Momento sexta ordem e Variância, sd = sem defeito, PI= defeito na pista Interna, PE= defeito. na pista Externa e ES= defeito. na Esfera

A partir dos dados obtidos, foram geradas quatro matrizes (20x6) (Matriz .01), a primeira continha os dados dos rolamentos sem defeito, a segunda os dados dos rolamentos com defeito na pista interna, a terceira dos dados dos rolamentos com defeito na pista externa e a quarta os de defeito na esfera.

$$\begin{array}{cccccc}
 RMS & Var & Ass & Curt & M(6) & FatK \\
 \begin{bmatrix}
 a_{(1,1)} & a_{(1,2)} & a_{(1,3)} & a_{(1,4)} & a_{(1,5)} & a_{(1,6)} \\
 \bullet & \bullet & & & & \bullet \\
 \bullet & \cdot & \bullet & & & \bullet \\
 \bullet & & \cdot & \bullet & & \bullet \\
 \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\
 a_{(20,1)} & a_{(20,2)} & a_{(20,3)} & a_{(20,4)} & a_{(20,5)} & a_{(20,6)}
 \end{bmatrix}
 \end{array} \quad (01)$$

Foram retiradas, de forma aleatória, 10 linhas de cada matriz. Sendo obtidas 40 linhas que foram misturadas, obtendo-se uma matriz 40x6, (Matriz .02).

$$\begin{array}{cccccc}
 RMS & Var & Ass & Curt & M(6) & FatK \\
 \begin{bmatrix}
 a_{(1,1)} & a_{(1,2)} & a_{(1,3)} & a_{(1,4)} & a_{(1,5)} & a_{(1,6)} \\
 \bullet & \bullet & & & & \bullet \\
 \bullet & \cdot & \bullet & & & \bullet \\
 \bullet & & \cdot & \bullet & & \bullet \\
 \bullet & \bullet & \bullet & \bullet & \bullet & \bullet \\
 a_{(40,1)} & a_{(40,2)} & a_{(40,3)} & a_{(40,4)} & a_{(40,5)} & a_{(40,6)}
 \end{bmatrix}
 \end{array} \quad (01)$$

A Matriz (02) foi usada para fase de treinamento da rede. Como de cada matriz com

dimensões iguais as da Matriz (01) restaram 10 linhas das, sendo 5 linhas escolhidas de forma aleatória, obtendo-se um total de 20 linhas que foram usadas em substituição de 20 linhas da Matriz (02). Obtendo-se outra matriz de 40x6, que foi usada na fase de treinamento da rede neural. Com as 5 linhas que ainda não haviam sido utilizadas, foi feito um procedimento similar ao anterior e a matriz obtida foi usada para fase de validação.

Diversas arquiteturas de redes foram testadas. As arquiteturas com duas camadas resultaram em índice de acerto muito baixo. Por outro lado, em algumas arquiteturas com mais de 3 camadas os resultados foram similares aos obtidos pela arquitetura de 3 camadas, porém com um tempo de treinamento superior. Optou-se, portanto, pelo uso de 3 camadas, sendo utilizados 10 neurônios na camada de entrada, 5 neurônios na camada oculta e 4 neurônios na camada de saída.. Para a rede neural escolhida foram definidos os seguintes parâmetros de treinamento:

- Camada de Entrada e Camada Oculta: Função de Ativação Tangente Hiperbólica;
- Camada de Saída: Função de Ativação Linear;
- Método de Otimização: Levenberg-Marguard;
- Número de Épocas: 500 Épocas;
- Erro Total Admissível:  $1e-5$ .

A rede neural foi implementada no MATLAB 6.5, e a mesma foi processada em um computador Pentium IV com processador 2,4 GHz e com uma memória RAM de 512 MB.

Os resultados mostrados na Tabela (01) foram obtidos ao final do processo. Pode-se observar que a rede teve um nível de acerto de 100% na indicação de falhas, e em alguns casos conseguiu identificar o tipo de falha, o que mostra que esta técnica é uma boa estratégia de identificação de falhas em rolamentos.

Parâmetros	Rede	Tipo de Falha		Detecção de Falha		Épocas	Tempo
		Teste	Valida.	Teste	Valida.		
R V S	10 x 5 x 4	75%	55%	100%	100%	*1500	30,75s
V S C	10 x 5 x 4	80%	75%	100%	100%	101	2,92s
R V S C	10 x 5 x 4	80%	75%	100%	100%	28	1,42s
R V S C M	10 x 5 x 4	80%	70%	100%	100%	35	1,70s
V S C M F	10 x 5 x 4	85%	80%	100%	100%	37	2,17s

**Legenda:** R= RMS, V= Variância, S = Assimetria, C = Curtose, M = Momento(6) e F = Fator K

Mesmo em alguns casos, onde a rede não foi capaz de identificar de forma correta o tipo de defeito, o nível de acerto foi considerável. A Figura (6.a) mostra uma situação onde a rede indicou a presença de falha porém, era defeito na pista externa e o resultado obtido foi defeito na esfera. Na Figura (6.b), o resultado esperado era defeito na pista interna e a saída da rede foi de defeito na esfera. Na Figura (6.c), o resultado correto era de defeito na pista interna, todavia, o resultado obtido foi de defeito na pista externa. Um dado bastante importante, a ser ressaltado, é o fato de toda vez que o rolamento estava sem defeito a rede sempre apresentava o resultado satisfatório, Figura (6.d). O que mostra que a rede teve um ótimo desempenho, pois é mais importante a indicar a presença de falha do que a identificação do seu tipo. Pois, a parada da máquina para a manutenção independe do tipo de falha apresentada pelo rolamento.

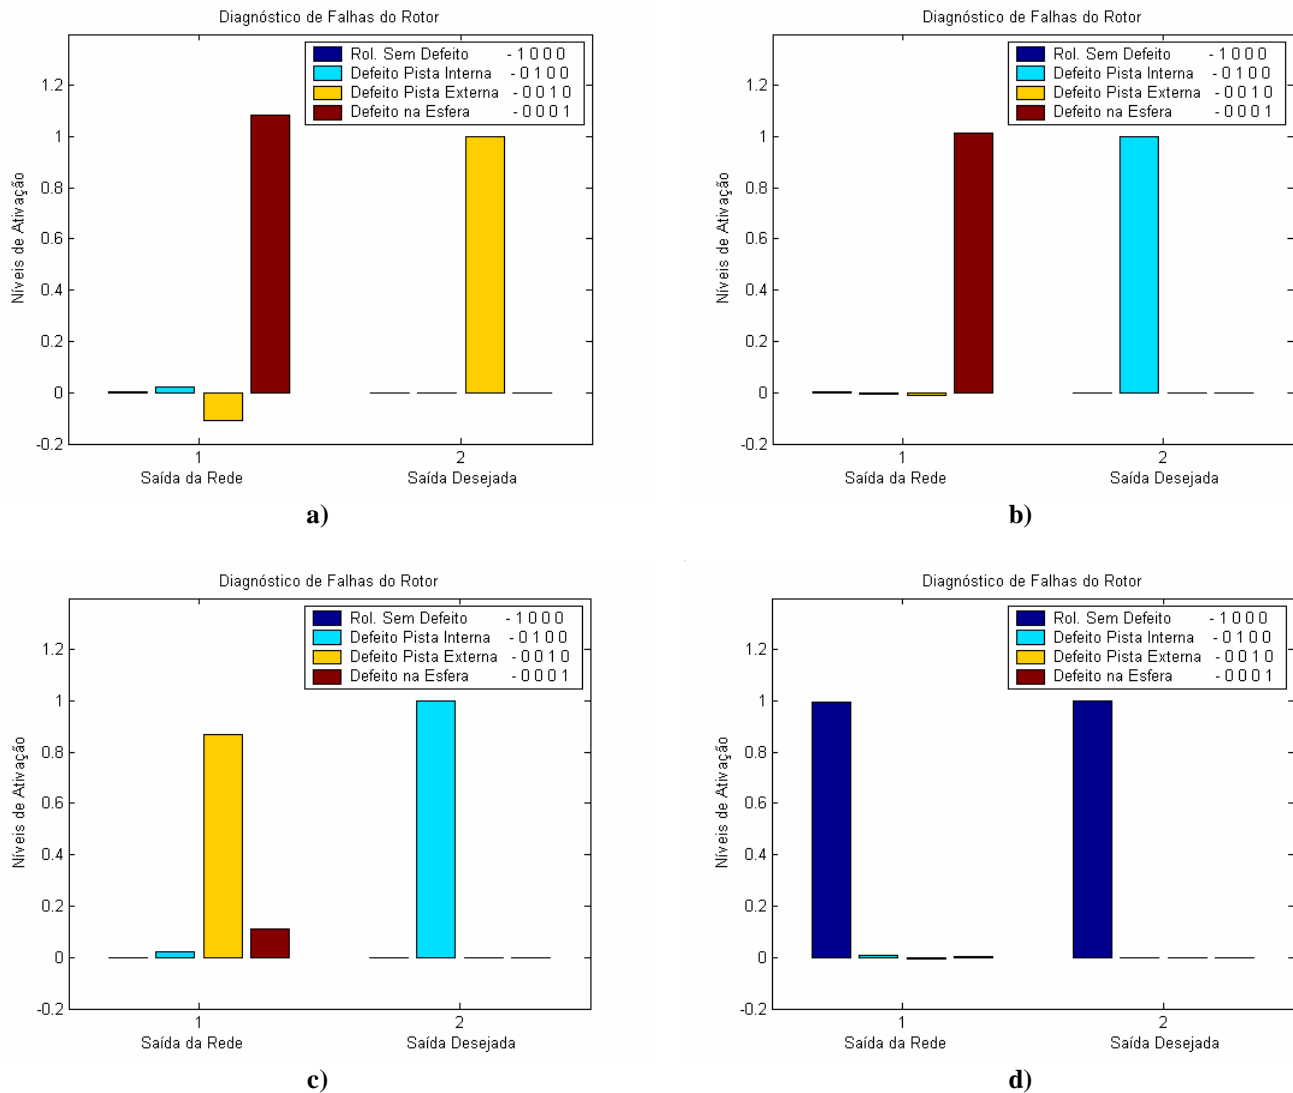


Figura 6. Resultados obtidos na Rede.

### 3. COMENTÁRIOS FINAIS

A partir dos resultados obtidos, pode-se concluir que: a utilização de poucos parâmetros estatísticos como dados de entrada da rede foi capaz de indicar a presença de falha no rolamento. Com o aumento do número de parâmetros estatísticos a identificação do tipo tem uma melhora significativa.

Com o uso de uma rede neural estes dados podem ser analisados sem dificuldade e sem a necessidade de conhecimento técnico para a interpretação dos resultados obtidos. Outra grande vantagem do uso da rede neural é fato da mesma ser capaz de indicar as falhas no seu estágio inicial, o que é muito importante para a manutenção preditiva.

### 4. AGRADECIMENTOS

- À INA Brasil, pelo seu apoio às pesquisas que estão sendo desenvolvidas pelo nosso Grupo de pesquisa.
- À CAPES pela concessão de uma bolsa PICDT de Doutorado.

- Ao departamento de Engenharia Mecânica da UFC que concedeu o meu afastamento para cursar o Doutorado na Universidade Estadual de Campinas - Unicamp.

## 5. REFERENCIAS

- Bolaers, F., Cousinard, O. Marconnet. P., and Rasolofondraibe, L., “Advanced Detection of Rolling Bearing Spalling From de-noising Vibration Signals”, 2003, Control Engineering Practice, Vol.8, pp. 01-10.
- Haykin, Simon, “Redes Neurais”, 2001, Editora Bookman, Porto Alegre – Brasil.
- Kowalski, C. T., Kowalska T. O., 2003, “Neural Networks Application for Induction Motor Faults Diagnosis”, Mathematics and Computers in Simulation, Article in Press, pp 1-14.
- Lin, Chang-Ching and Wang Hsu-Pin, 1996, “Performance Analysis of Rotating Machinery Using Enhanced Cerebellar Model Articulation Controller (E-CMAC) Neural Networks” Computers Ind. Engng., Vol.30, No. 2, pp. 227-242.
- Martin, H. R., Honarvar, F., 1995, “Application of Statistical Moment to Bearing Failure Detection”, Applied Acoustics, Vol. 44, pp. 67-77.
- Mesquita, A. L. A., Santiago, D. F. A., Bezerra, R. A., Miranda, U. A., Dias, M., and Pederiva. R., 2002, “Detecção de Falhas em Rolamentos Usando Transformadas Tempo-Frequência – Comparação com Análise de Envelope”, Mecânica Computacional, Vol. XXI, pp. 1938-1954.
- Samanta, B. and Al-Blalushi K. R., 2001, “Artificial Neural Network Based Fault Diagnostics of Rolling Element Bearings Using Time-Domain Features”, Mechanical Systems and Signal Processing, Vol. 17, No. 2, pp. 317-328.
- Santiago, D. F. A., Brito, J. N., Pederiva, R., 2002, “Diagnóstico de Falhas em Máquinas Rotativas Utilizando Redes Neurais”, II Congresso Nacional de Engenharia Mecânica.
- Silva, A. A., 1999, “Detecção e Análise Dinâmica de Falhas em Rolamentos”, Tese de Doutorado, Universidade de São Paulo, Escola de Engenharia de São Carlos.
- Tandon, N. and Choudhury, A., “A Review of Vibration and Acoustic Measurement Methods for the Detection of Defects in Rolling Element Bearings”, 1999, Tribology International. Vol. 32, pp. 469-480.
- Tse, P.W., Peng, Y. H., Yan, R., 2001, “Wavelets Analysis and Envelope Detection For Rolling Element Bearing Fault Diagnosis – Their Effectiveness and Flexibilities”, Journal of Vibration and Acoustics, Vol. 123, pp. 303-310.
- Yang, D. M., Stronach, A. F., MacConnell, P. and Penman, 2002, “Third-Order Spectral Techniques for Techniques for the Diagnosis of Motor Bearing Conditions Using Artificial Neural Networks”, Mechanical Systems and Signal Processing, Vol. 16, No.2, pp. 391-411.

## USE OF NEURAL NETWORK TO IDENTIFY FAULTS IN BEAIRNG FROM STATISTICAL PARAMETERS

### **Roberto de Araújo Bezerra**

UNICAMP / Faculty of Mechanical Engineering - UFC/ Ceará

Caixa Postal 6051 – Campinas –SP – CEP: 13083-970- [roberto@fem.unicamp.br](mailto:roberto@fem.unicamp.br) – [bezerra\\_roberto@yahoo.com.br](mailto:bezerra_roberto@yahoo.com.br)

### **Darley Fiácro de Arruda Santiago**

UNICAMP / Faculty of Mechanical Engineering - CEFET/ Piauí

Caixa Postal 6051 – Campinas –SP – CEP: 13083-970 - [darley@fem.unicamp.br](mailto:darley@fem.unicamp.br)

### **Robson Pederiva**

UNICAMP / Faculty of Mechanical Engineering

Caixa Postal 6051 – Campinas –SP – CEP: 13083-970- [robson@fem.unicamp.br](mailto:robson@fem.unicamp.br)



**Abstract**

*In the predictive maintenance the determination of fault in its initial stage is an indispensable prerequisite for the used techniques. The presence of faults in rolling bearing can be detected in its initial stage, through techniques of vibratory analysis in the time domain and frequency domain. In the frequency domain, there are several techniques that identify moreover the presence of the fault, they can identify what kind of fault the rolling bearing has. However, most of these techniques demand technical knowledge to the correct diagnosis. On the other hand, the techniques in the time domain, that use statistical parameters, in some cases, can indicate the presence of fault, however, they can not determine what kind of fault the rolling bearing has. Using rolling bearings with induced faults, in the inner race, outer race and ball, it will be applied several techniques in time domain. The statistical parameters will be used in the training process of a neural network, in order to automate and to establish a fast and reliable criterium of the fault identification.*

**Word-key:** *Automatic diagnosis of fault, Neural Network, Rolling Bearing, Predictive Maintenance.*