

UTILIZAÇÃO DE REDES NEURAIS PARA DIAGNÓSTICO DE FALHAS MECÂNICAS EM MOTORES DE INDUÇÃO TRIFÁSICOS

Lane Maria Rabelo Baccarini¹, Benjamim Rodrigues de Menezes², Walmir Matos Caminhas³

¹Departamento de Engenharia Elétrica - UFSJ

Pça Frei Orlando, 170 – São João del Rei, 170 – 36300.000

²Departamento de Engenharia Elétrica – UFMG

Av. Antônio Carlos, 6627 – Belo Horizonte – 31270.010

E-mails: rabelo@cpdee.ufmg.br, brm@cpdee.ufmg.br, caminhas@cpdee.ufmg.br

Abstract

Vibrations analysis continues to be one of the most versatile and informative tool available for on-line monitoring and problem analysis. This paper presents a fault diagnostic system using neural network. From experimental results in a test desk, deterministic frequencies are identified and used to detect four states in a induction motor: normal operation, unbalance, misalignment and mechanical looseness. Using neural network, it is possible to detect and diagnose mechanical sources in a induction machine with improved results.

1. Introdução

A síntese das pesquisas realizadas pelo EPRI (Electrical Power Research Institute) e IEEE (Institute Engineers Electrical and Electronic), mostra que as avarias em motores devido às causas não identificadas apresenta percentuais expressivos [1]. Isto nos leva a concluir que os estudos para identificação das falhas em motores elétricos têm um campo amplo a ser explorado.

A detecção de defeitos quando estes estão ainda em fase de desenvolvimento, através da comparação de espectros de vibração ou do espectro de corrente, possibilita o planejamento de uma ação corretiva com relação ao defeito previsto. Este procedimento pode reduzir o tempo de manutenção e prevenir falhas catastróficas em uma planta industrial. Contudo, a detecção do desenvolvimento de um defeito requer um diagnóstico correto do problema para que a ação tomada seja efetiva.

Desenvolver ferramentas computacionais e técnicas experimentais capazes de detectar e diagnosticar falhas em motores elétricos, tanto as de origem elétrica como as de origem mecânica, é sem dúvida um grande desafio para a engenharia.

Neste trabalho serão aplicadas duas topologias de redes neurais artificiais (RNA) para diagnóstico de falhas mecânicas num motor de indução trifásico.

A metodologia desenvolvida é simples, apresentando alto desempenho e baixo tempo de simulação.

A rede é usada para classificar a excitação para quatro condições de operação do motor: operação sem defeito, desbalanceamento, desalinhamento e folga mecânica.

Os sinais de vibração foram coletados numa bancada de teste montada no laboratório de Conversão de Energia da Universidade Federal de São João del Rei, em seis posições distintas., tanto no lado do ventilador quanto no lado do acoplamento do motor com a carga.

Através de um filtro seletivo desenvolvido por Brito [1] foi possível reduzir o número de parâmetros capazes de representar os sinais utilizados para o treinamento das redes neurais.

2. Causas Usuais de Vibração

2.1 Desbalanceamento

O desbalanceamento é uma das fontes mais comuns de vibrações em máquinas rotativas. As características de desbalanceamento são fáceis de entender. Ele existe quando a distribuição de massas de um rotor não é uniforme em relação a um eixo de inércia. Com o rotor em rotação, forças centrífugas giratórias causam reações alternadas nos mancais, ou seja, vibrações. Assim, a vibração dominante ocorrerá na frequência da rotação do rotor e terá amplitudes maiores nas direções radiais, ficando o nível axial baixo.

2.2 Desalinhamento

Desalinhamentos constituem outra grande causa de desgaste de componentes de máquinas. O desalinhamento é o desvio em relação à linha de centro durante a operação da máquina. Até pouco tempo atrás, desalinhamentos eram considerados a segunda fonte de vibrações em máquinas, porém, os programas preditivos

que atualmente estão sendo implantados mostram que estes são bem mais frequentes que os desbalanceamentos.

Problemas sérios de vibrações podem acontecer mesmo quando acoplamentos são alinhados dentro das tolerâncias especificadas pelos fabricantes. Para um alinhamento correto, deve-se recorrer às novas ferramentas óticas ou lasers.

2.3 Folga Mecânica

A folga mecânica se caracteriza pela presença de múltiplos harmônicos da frequência de rotação (1xfr). Gera vibrações em máquinas rotativas devido a parafusos frouxos, folgas excessivas nos mancais, entre outros. Este tipo de vibração não ocorre sem que haja outras forças excitando o sistema, tais como desbalanceamento e desalinhamento.

Quando há folga mecânica excessiva, mesmo nos pequenos desbalanceamentos e desalinhamentos, aparecem elevados níveis de vibração, ou seja, as folgas mecânicas amplificam as vibrações. O plano dominante é o radial.

3. Bancada de Teste

Na figura 1 tem-se a fotografia da bancada experimental que foi montada no Laboratório de Conservação de Energia da Universidade Federal de São João del Rei.

Os testes foram realizados para as seguintes condições de funcionamento: operação normal; desbalanceamento com 21g; desbalanceamento com 35,1g; desalinhamento e folga mecânica.

Para a coleta dos sinais usou-se o equipamento *UltraSpec 8000* [1] fabricado pela CSI - *Computational Systems Incorporated*, ferramenta do programa de Manutenção Baseada em Confiabilidade.

Os sinais de vibração foram obtidos utilizando-se um acelerômetro [3] A0720GP, SN6714, com sensibilidade de 0.1000 mV. Usou-se uma janela *Hanning* com 3200 linhas e 10 médias, para uma faixa de frequência de 0 a 400 Hz. As amplitudes foram medidas em velocidade (mm/s).

Os sinais foram coletados com o acelerômetro colocados alternadamente nas posições vertical, horizontal e axial, tanto do lado do ventilador quanto do lado do acoplamento do motor. Estas posições serão identificadas por três letras. A primeira será sempre **A** de acoplado, a segunda poderá ser **V** de vertical; **A** de axial ou **H** de horizontal e a última poderá ser **V** de ventoinha ou **A** de acoplamento.

Os defeitos foram introduzidos num motor de indução trifásico [4], fabricação WEG (FH 88747), rotor do tipo gaiola, 5 CV, 1730 rpm, 220 V, 60 Hz, categoria N, 4 polos, 44 barras no rotor, 36 ranhuras no estator, rolamento SKF 6205-2Z, ID-1, carcaça 100L,

FS 1,15, Ip 7.5 pu, IP 55, In 13.8 A. O motor foi doado pela WEG Motores.

Um gerador CC [5] alimentando um banco de resistências [6] é utilizado como sistema de carga e está acoplado ao motor elétrico através de um acoplamento flexível [7], doado pela Flender do Brasil Ltda.

Usou-se uma monitoração paralela através de um voltímetro de precisão ENGRO; amperímetro alicate digital DAWER/CM-600 e *Optho Tako*. O objetivo dessa monitoração é garantir o funcionamento do motor em teste com corrente nominal, possibilitando que os defeitos introduzidos tornem-se mais perceptíveis nos espectros.



Figura 1 – Bancada de Teste

Através de *firmwares* específicos disponíveis no *UltraSpec 8000*, fez-se o balanceamento e alinhamento a laser da bancada de teste, verificando-se também possíveis folgas mecânicas (base frouxa do motor). Com isso pode-se obter os espectros de vibração para a condição considerada sem defeito, conforme exemplo apresentado na figura 2.

A excitação por desbalanceamento foi obtida alterando o valor da massa de desbalanceamento e a sua posição angular em relação à de referência. As massas de desbalanceamento, 21g e 35,1g, foram colocadas no disco do lado do ventilador. O espectro na posição vertical do lado da ventoinha é mostrado na figura 3, para massa de 35,1 g.

A excitação por desalinhamento foi obtida desnivelando a bancada através de dois parafusos de alinhamento vertical, lado do ventilador. Na figura 4, tem-se o espectro de vibração para o desalinhamento, posição vertical.

A excitação por folga mecânica foi obtida através do afrouxamento dos parafusos de fixação do motor à base da bancada. Na figura 5, tem-se o espectro de vibração para posição vertical.




Figura 2: Espectro para a condição sem defeito,




Figura 5: Espectro de vibração, folga mecânica.




Figura 3: Espectro de vibração, desbalanceamento




Figura 4: Espectro de vibração, desalinhamento

Os dados coletados através da análise de vibração trazem nos espectros, além das informações relacionadas com os defeitos propriamente ditos, que são as frequências determinísticas dos defeitos, outras informações que podem ser descartadas, inclusive ruídos.

No uso de redes neurais a definição de sua arquitetura e do treinamento são etapas que dependem diretamente da quantidade e da qualidade dos dados utilizados. Geralmente os sinais de entrada para o processo de aprendizado das redes neurais são compactados, aumentando sua eficiência e seu desempenho computacional.

Oliveira (1999) aplicou uma técnica estatística de compactação de sinais baseada na análise dos autovalores da matriz de covariância dos dados.

Léporé et al (2000), utilizaram a técnica de decomposição *wavelet* para promover a redução do número de parâmetros capazes de representar os sinais utilizados para o treinamento das redes neurais.

Schoen et al (1995) utilizaram um filtro de frequência seletivo baseado em regras, que determinava quais frequências deveriam ser monitoradas pela rede neural.

Baseado no trabalho de Schoen, Brito desenvolveu um sistema para selecionar as entradas de dados, a partir da frequência de rotação (f_r), frequência nominal de linha, rotação nominal do motor e o número de ranhuras.

O programa “FiltroSeletivo”, desenvolvido na linguagem C++, seleciona somente as frequências determinísticas relacionadas com os defeitos estudados. Este procedimento reduz significativamente o número de informações a ser enviado para a Rede Neural, eliminando ruídos e redundâncias.

4. Descrição da Topologia

Adotou-se duas topologias de redes para a análise dos defeitos de origem mecânica que serão denominadas de “rede MLP-global”, e de “rede *max-net*”.

As frequências determinísticas selecionadas através do Filtro que correspondem às entradas da rede neural são:

$$fr, 2fr, 3fr, 4fr.$$

onde:

fr é a frequência de rotação do motor

A tabela 1 apresenta a quantidade de padrões selecionadas para o treinamento e validação da rede para cada excitação e posição do sensor,

Tabela 1 – Dados de treinamento e validação da rede

	P1	P2	P3	P4	P5	P6
Treinamento						
<i>Sem defeito</i>	36	38	37	38	38	38
<i>Desalinhamento</i>	33	33	33	33	33	33
<i>Desbalanceamento</i>	61	60	60	60	60	60
<i>Folga Mecânica</i>	32	32	32	33	32	32
Validação						
<i>Sem defeito</i>	12	12	12	12	12	12
<i>Desalinhamento</i>	10	10	10	10	10	10
<i>Desbalanceamento</i>	20	20	20	20	20	20
<i>Folga Mecânica</i>	10	10	10	10	10	10

onde:

- P1- vertical, lado da ventoinha (AVV);
- P2 – axial, lado da ventoinha (AAV);
- P3 – horizontal, lado da ventoinha (AHV);
- P4 – vertical, lado do acoplamento (AVA);
- P5 – axial, lado do acoplamento (AAA);
- P6 – horizontal, lado do acoplamento (AHA).

4.1 Rede MLP-global

A “rede MLP-global”, figura 6, com duas camadas, 7 neurônios na camada escondida, apresenta duas saídas binárias y_1 e y_2 , correspondendo às seguintes situações:

- 00 – *sem defeito*
- 01 – *desalinhamento*
- 10 – *desbalanceamento*
- 11 – *folga mecânica*

A tabela 2 mostra os resultados obtidos para a fase de validação para cada posição do sensor. Os valores apresentados representam o número de padrões que a rede errou para cada excitação. A última linha representa o percentual de acertos.

As funções de ativação utilizadas para as duas camadas foi a *sigmoidal* e usou o algoritmo *backpropagation* para o ajuste dos pesos.

Tabela 2 – Resultados da rede MLP-global

	P1	P2	P3	P3	P4	P5
<i>Sem defeito</i>	2	0	3	2	2	2
<i>Desalinhamento</i>	0	0	2	2	2	1
<i>Desbalanceamento</i>	0	4	0	4	1	0
<i>Folga Mecânica</i>	1	3	4	0	2	2
<i>Total de erros</i>	3	7	9	8	7	5
<i>Acertos em %</i>	94	86	83	84	86	90




Figura 6 – Rede MLP-global

Observa-se que a posição 1, AVV (direção vertical, lado da ventoinha), correspondeu a melhor posição para a coleta de dados através de acelerômetro.

Adotando-se o método multi-objetivo desenvolvido em [2] consegue-se melhorar o desempenho da rede, conforme resultados apresentados na tabela 3. Em contra-partida tem-se um aumento significativo do tempo de treinamento.

Tabela 3 – Resultados da rede usando multiobjetivo

		P2	P3	P4	P5	P6
<i>Sem defeito</i>		1	2	2	1	0
<i>Desalinhamento</i>		0	2	1	1	0
<i>Desbalanceamento</i>		2	0	1	1	0
<i>Folga Mecânica</i>		1	1	0	1	2
<i>Total</i>		4	5	4	4	2
Total em %		92	90	92	92	96

4.2 Rede Max-Net

A rede única com duas saídas, figura 6, apresentou desempenho excelente para o diagnóstico de falhas em motores, tabela 3. Entretanto, esta topologia de rede não possibilita visualizar a evolução do defeito. Assim adotou-se a topologia denominada de “Max-Net”, figura 7. Nesta configuração, as quatro redes multicamadas: - *MLP1 a MLP4* - foram treinadas para reconhecer respectivamente as seguintes situações: sem defeito, desalinhamento, desbalanceamento e folga mecânica. Todas as redes foram simuladas usando a rotina trainlm do software “matlab”.




Figura 7 – Rede Max-net

A rede MLP1, com 10 neurônios na camada escondida, foi treinada para separar a saída em duas classes: sem defeito e com defeito. As saídas da rede estão no intervalo de 0 a 1. Saída próxima de 1 corresponde a máquina operando nas condições normais sem defeito - e saída próxima de 0 indica defeito mecânico.

A rede MLP2, com 10 neurônios na camada escondida, foi treinada para analisar a situação de desalinhamento. Saída próxima de 1 corresponde a máquina desalinhada e próxima de zero às outras situações (sem defeito, desbalanceamento ou folga mecânica)

A rede MLP3, com 7 neurônios na camada escondida, foi treinada para analisar a situação de desbalanceamento. Saída próxima de 1 corresponde a

máquina desalinhada e próxima de zero às outras situações (sem defeito, desalinhamento ou folga mecânica).

A rede MLP4, 10 neurônios na camada escondida, foi treinada para analisar a situação de folga mecânica. Saída próxima de 1 corresponde a folga mecânica e próxima de zero podendo corresponder à desalinhamento, desbalanceamento ou sem defeito. A saída final da rede será obtida maximizando as saídas das redes individuais *MLP1 a MLP4*.

A tabela 4 mostra os resultados finais da rede max-net para as 6 posições diferentes de coleta de dados. Observa-se que a rede conseguiu classificar corretamente quase a totalidade dos dados apresentados durante a validação para a posição P1. Além disso pode-se avaliar o desempenho individual de cada rede analisando a tendência de falhas.

Tabela 4 – Resultados da rede Max-Net

	P1	P2	P3	P4	P5	P6
<i>Sem defeito</i>	0	1	0	2	1	2
<i>Desalinhamento</i>	0	0	2	0	1	1
<i>Desbalanceamento</i>	0	3	0	2	2	2
<i>Folga Mecânica</i>	2	1	3	0	3	0
<i>Total</i>	2	5	5	4	7	5
Total em %	96	90	90	92	86	90

O tempo de simulação das redes MLP-global e max-net, foram, respectivamente, 40 segundos e 180 segundos. Assim a rede max-net apresentou tempo de simulação de 4 vezes superior à mlp-global.

5. Conclusões

A utilização de Redes Neurais Artificiais mostrou extremamente eficiente para o diagnóstico de falhas mecânicas em motores elétricos trifásicos. Algoritmos simples de aprendizagem em redes com apenas duas camadas foram suficientes para alcançar excelentes desempenhos.

A aplicação de Redes Neurais na detecção de falhas possibilita a realização do diagnóstico on line, sendo capazes de diagnosticar falhas sem a ajuda de especialistas da manutenção.

Neste trabalho, pôde-se verificar também que a melhor posição para aquisição e análise de sinais é a posição vertical.

Pretende-se agora fazer análises similares incorporando falhas elétricas (desequilíbrio de fases e *single-phasing*) e barras quebradas, obtendo uma rede completa para análise de falhas em motores.

6. Agradecimentos

Ao aluno de doutorado da UFMG Marcelo Costa pelas valiosas sugestões e ao professor da Universidade Federal de São João del Rei, Jorge Nei Brito por ter disponibilizado os dados.

Agradecemos também à CAPES/PICDT pela bolsa de doutorado, FAPEMIG e CNPQ pelo financiamento do projeto.

Referências Bibliográficas

- [1] Brito, Jorge N. (2002) – Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos – Tese de Doutorado – Universidade Estadual de Campinas – Faculdade de Engenharia Mecânica
- [2] Teixeira, Roselito A – Treinamento de Redes Neurais Artificiais Através de Otimização Multi-Objetivo: Uma Nova Abordagem para o Equilíbrio entre a Polarização e a Variância – Tese de Doutorado – Universidade Federal de Minas Gerais – Programa de Pós-Graduação em Engenharia Elétrica - 2001
- [3] Lépure, F.P., Santos, M.B. Oliveira, A. G. – “Detecção de defeitos em máquinas rotativas utilizando redes neurais artificiais e sinais de vibração tratados utilizando wavelets” Congresso Nacional de Engenharia Mecânica, Natal, Brasil, Proc. In. CDROM, 2000.
- [4] Lépure, F.P., Santos, M. B. “Modal parameters extraction using wavelets” XV Congresso Brasileiro de Engenharia Mecânica, Águas de Lyndioia, São Paulo, Brasil, Proc. In CDROM, 1999
- [5] Oliveira, A. G. “Técnicas de caracterização de excitações em máquinas rotativas. Uberlândia: Universidade Federal de Uberlândia, 1999, 207 p. Tese (Doutorado).
- [6] Schoen, R.R., Lin, B. K., Habetler, T.G., Schlag, J. H., Farag, S – “An unsupervised, on-line system for induction motor fault detection usin stator current monitoring”. IEEE Transactions on Industry Application, v.31 (6), pp 1280-1286, 1995