

CLASSIFICAÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO REDES NEURAI ARTIFICIAIS

WAGNER FONTES GODOY¹, IVAN NUNES DA SILVA², WYLLIAM SALVIANO GONGORA³, ALESSANDRO GOEDEL¹, RODRIGO HENRIQUE CUNHA PALÁCIOS¹.

1. *Departamento de Engenharia Elétrica, Universidade Tecnológica Federal do Paraná
Av. Alberto Carazzai, 1640, Cornélio Procópio, PR, Brasil
E-mails: wagnergodoy@utfpr.edu.br, agoedtel@utfpr.edu.br, rodrigopalacios@utfpr.edu.br*

2. *Departamento de Engenharia Elétrica, Universidade de São Paulo
Av. do Trabalhador São Carlense, 400, São Carlos, SP, Brasil
E-mail: insilva@sc.usp.br*

3. *Departamento de Elétrica, Instituto Federal do Paraná
Av. Cívica, 475, Assis Chateaubriand, PR, Brasil
E-mail: wylliam.gongora@ifpr.edu.br*

Abstract—The induction motor is considered one of the most important elements in manufacturing processes. The use of strategies based on intelligent systems capable to classify the presence or absence of failures and also to determine its origin for the diagnosis and faults prediction is widely investigated in three phase induction motors. Thus, the aim of this paper is to present a classification bearing failures methodology based on neural networks, by using voltages and electric currents values in the time domain. Experimental results collected at real industrial process are presented to validate this proposal.

Keywords—Artificial Neural Networks, Failures prediction, Three phase induction motor.

Resumo—O motor de indução trifásico é considerado um dos mais importantes elementos nos processos produtivos. A utilização de estratégias baseadas em sistemas inteligentes capazes de classificar a existência ou não das falhas bem como determinar a origem das mesmas para diagnóstico e predição de falhas em motores de indução trifásicos tem sido amplamente investigada. Assim, a proposta deste trabalho é apresentar uma metodologia de classificação de falhas em rolamentos de motores de indução trifásicos baseada em redes neurais, utilizando os valores das tensões e correntes elétricas no domínio do tempo. Resultados experimentais coletados em processos industriais reais são apresentados para validar a proposta.

Palavras-chave—Redes Neurais Artificiais, Predição de falhas, Motor de indução trifásico.

1 Introdução

O setor industrial brasileiro consome 44% da energia elétrica do país, sendo que 62% dessa energia é utilizada em sistemas motrizes (Eletrobrás, 2012), o que evidencia a relevância do motor de indução trifásico (MIT) nas mais diversas aplicações industriais.

Visando obter a máxima eficiência nos processos e consequente aumento de produtividade, os motores elétricos, assim como os demais equipamentos inseridos em ambientes indústrias, necessitam de planos de manutenção alinhados com técnicas preditivas de diagnóstico e prevenção de falhas que possam conduzir à paradas indesejadas no processo (Baccarini, 2005).

Assim, pode-se considerar que a lucratividade de um processo está relacionada com a disponibilidade dos seus equipamentos, preservação do meio ambiente e manutenção da integridade das pessoas e processos. A busca contínua pela redução de custos, obriga o desenvolvimento de planos e estratégias que possam ser utilizados para prever e eliminar possíveis falhas e quebras indesejadas em máquinas e instala-

ções, entre outros, diminuindo assim seus gastos por paradas não programadas.

Com isso podem ser empregados vários tipos de manutenção, como por exemplo, a Manutenção Preditiva. Essa técnica permite avaliar as condições reais de operação das máquinas através da análise de dados coletados diretamente do equipamento, permitindo minimizar a ocorrência de falhas inesperadas.

De acordo com Araújo *et al.* (2011), publicações sobre a confiabilidade de motores demonstram que os rolamentos representam a principal causa de falhas em motores assíncronos. Na ocorrência de falha, o motor apresenta indícios de defeitos de várias formas, possibilitando assim sua correta identificação ainda em fase de evolução.

Inseridos neste contexto, os sistemas inteligentes têm sido utilizados na identificação e resolução de diversos problemas relacionados ao controle e acionamento de máquinas elétricas sendo capazes de classificar e determinar a origem de falhas ainda em evolução (Santos *et al.*, 2011; Sayouti *et al.*, 2011).

Os sistemas inteligentes aplicados ao diagnóstico de máquinas são baseados nas Redes Neurais Artificiais, Lógica Fuzzy e Sistemas Híbridos (Ghate e Dudul, 2009; Seera *et al.*, 2012).

O trabalho de Chow *et al.* (1991); Faraco *et al.* (1998), trata do estudo de dois tipos de falhas incipientes em um motor de indução com rotor do tipo gaiola de esquilo, quais sejam, falhas no enrolamento estatórico e deterioração dos rolamentos.

Seguindo a estrutura proposta por Chow *et al.* (1991), o conjunto inicial de treinamento é composto apenas por valores eficazes de corrente e velocidade $\{I, W\}$, e foi expandido para 5 combinações $\{I, W, I^2, W^2, I \times W\}$, propiciando assim uma melhor precisão e redução no tempo de treinamento.

Assim, o objetivo é apresentar uma estratégia de detecção de falhas em rolamentos de motores de indução trifásicos baseada em RNA com a análise dos sinais de corrente (I) e tensão (V) no domínio do tempo, combinando as estruturas de entradas da rede.

Um estudo comparativo entre duas estruturas neurais é também apresentado neste trabalho. Na primeira rede utilizam-se como entrada apenas $\{I, V\}$, enquanto na segunda rede utilizam-se $\{I, V, I^2, V^2, I \times V\}$.

Este artigo está organizado da seguinte forma: na Seção 2, uma descrição das principais falhas em motores elétricos. Na Seção 3, os dados relativos à RNA aplicada neste trabalho. Na Seção 4, tem-se a metodologia proposta para avaliação de desempenho das redes e também serão apresentados os resultados com dados experimentais. Finalmente, na Seção 5, as conclusões finais do trabalho são apresentadas.

2 Definição do problema

O monitoramento das condições de operação de um MIT possibilitando diagnóstico de falhas e previsão das suas condições de operação tem atraído a atenção de vários pesquisadores durante os últimos anos. Tal fato se deve à considerável influência do MIT sobre a continuidade operacional de muitos processos industriais (Bellini *et al.*, 2008).

A detecção e o correto diagnóstico precoce de falhas incipientes permite minimizar a ocorrência de danos ao processo, aumento da disponibilidade dos equipamentos e consequente manutenção dos resultados financeiros.

Os motores elétricos estão sujeitos a vários tipos de falhas, que podem ser divididas em dois grupos distintos: i) falhas elétricas e ii) falhas mecânicas (Bellini *et al.*, 2008). A Tabela 1 apresenta a classificação dos principais tipos de falhas em MIT.

Tabela 1. Tipos de falhas

Falhas Elétricas	Falhas Mecânicas
Enrolamento de estator	Desgaste de acoplamento
Enrolamento de rotor	Desalinhamento
Barras quebradas	Excentricidade
Anéis quebrados	Rolamento
Conexões	-

Fonte: Bellini, *et al.* 2008

Das falhas citadas na literatura (Kowalski e Orłowska-Kowalska, 2003; Han *et al.*, 2007), estima-se

que os rolamentos são responsáveis por aproximadamente 40% das paradas indesejadas dos MIT.

Assim, este artigo trata a investigação de falhas relacionadas aos rolamentos, uma vez que esta se refere ao tipo de falha incipiente mais comum em MIT. Ainda de acordo com Araújo *et al.* (2010), a deterioração de rolamentos também pode ocorrer em função das correntes de modo comum que circulam pelos mesmos devido à carga eletrostática induzida no eixo do motor. Outro fator refere-se às pulsações de conjugado causadas pela existência de harmônicos de baixa ordem na alimentação ou relativas a possíveis barras quebradas.

Métodos tradicionais consideram o monitoramento da temperatura e vibração dos rolamentos visando estimar suas condições de operação. No entanto, o custo de sensores para monitoramento de vibrações associados a dispositivos de processamento de sinais restringem sua utilização de uma forma geral.

A Figura 1 apresenta um gráfico comparativo entre os diversos tipos de falhas, conforme os estudos encomendados pelas agências IEEE (*Institute of Electrical and Electronics Engineers*) e EPRI (*Electric Power Research Institute*).

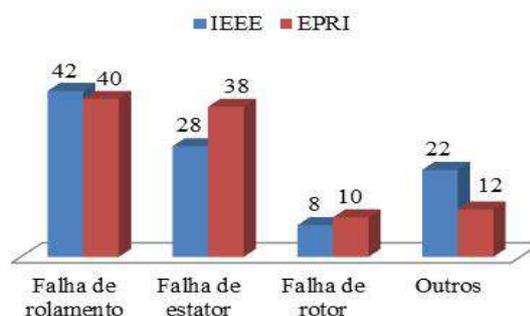


Figura 1.: Percentual de ocorrência de falhas em MIT

Para o caso em estudo neste trabalho, as tensões e correntes foram medidas em três MIT de 1; 7,5 e 12,5 CV respectivamente, do fabricante WEG. O motor de 1 CV é utilizado em laboratório, em perfeitas condições de operação, e os demais utilizados nos processos de calefação e moenda de cana de açúcar, ambos com problemas mecânicos de rolamento.

Resultados de análises de vibração efetuados pela empresa indicaram que os motores apresentavam falha de rolamento, no entanto, o tipo de falha não foi caracterizado. Assim, em processo foram coletados os dados dos motores em condições de falha. Após manutenção corretiva, novas medidas tanto de vibração mecânica como de corrente e tensão de alimentação dos referidos motores e não foram mais observadas alterações referentes às vibrações, inferindo-se o funcionamento adequado dos mesmos através da restauração dos sinais de corrente e tensão.

3 Redes Neurais Artificiais

As RNA são modelos computacionais inspirados no sistema nervoso de seres vivos para o processamento de informações paralelas (Silva *et al.*, 2010).

Tais modelos são uma composição simples de unidades de processamento interligadas entre si por conexões conhecidas como sinapses artificiais (Haykin, 2001).

As redes são modeladas matematicamente e tendem a imitar o processamento de informações por um neurônio cerebral humano, e, desta forma, adquirem a capacidade de aprendizagem e adequação do conhecimento.

O processamento das informações é efetuado através de cálculos matriciais, onde os valores apresentados na camada de entrada são multiplicados por uma constante, conhecida como peso sináptico. Estes novos valores, somados entre si, representam o valor do neurônio.

Tal unidade, por sua vez, é processada por uma função de ativação, característica do neurônio e modelo da rede. Assim, obtém uma resposta da rede já treinada (Rosenblatt, 1958), como observado na Figura 2.

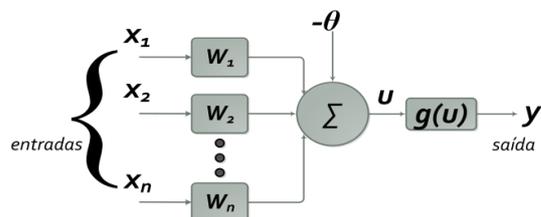


Figura 2. Neurônio artificial

Uma rede neural extrai seu potencial computacional máximo através de sua estrutura e sua habilidade de aprender e generalizar (Haykin, 2001). Tais redes produzem saídas adequadas mesmo recebendo entradas que não estavam no processo de treinamento, assim podendo até interpretar falsas leituras sem alterar resultados.

As RNAs podem ser empregadas para classificação de padrões, análise de séries temporais, mineração de dados, agrupamento de dados e estimação de resultados baseadas em um conhecimento previamente adquirido e em sua capacidade de generalização das situações (Haykin, 2001; Silva *et. al.*, 2010).

3.1 Rede Perceptron Multi-Camada (PMC)

As redes Perceptrons múltiplas camadas utilizam os mesmos princípios propostos por Rosenblatt (1958), com a diferenciação que apresentam uma ou mais camadas intermediárias, conhecidas como camadas escondidas. Estas podem estar contidas desde um simples neurônio a inúmeros, como exemplificado na Figura 3.

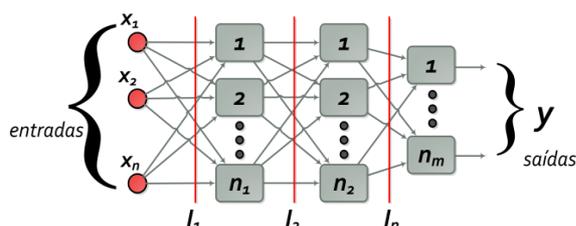


Figura 3. Modelo de uma rede PMC

A estrutura apresentada é proposta em uma grande diversidade de aplicações e pode ser utilizada como aproximador universal de função, classificação de padrões, identificação de sistemas, otimização, controle de processos entre outros (Haykin, 2001).

Seu treinamento é realizado de forma supervisionada, fazendo com que a rede ajuste adequadamente os pesos para melhor atender os objetivos.

Para um melhor entendimento do princípio de funcionamento envolvido com o algoritmo *backpropagation* (Silva *et. al.*, 2010), faz-se necessário definir diversas variáveis e parâmetros auxiliares que norteiam a derivação do algoritmo, a saber:

– $W_{ji}^{(L)}$ são matrizes de pesos cujos elementos denotam o valor do peso sináptico conectando ao j -ésimo neurônio da camada (L) ao i -ésimo neurônio da camada ($L-1$).

- $W_{ji}^{(3)}$ é o peso sináptico conectando ao j -ésimo neurônio da camada de saída ao i -ésimo neurônio da camada 2;
- $W_{ji}^{(2)}$ é o peso sináptico conectando ao j -ésimo neurônio da camada escondida 2 ao i -ésimo neurônio da camada 1;
- $W_{ji}^{(1)}$ é o peso sináptico conectando ao j -ésimo neurônio da camada 1 ao i -ésimo neurônio da camada de entrada;

– $I_j^{(L)}$ são vetores cujo os elementos denotam a entrada ponderada em relação ao j -ésimo neurônio da camada L , os quais são definidos por 1, 2 e 3:

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot x_i \leftrightarrow I_j^{(1)} \quad (1)$$

$$= W_{j,0}^{(1)} \cdot x_0 + W_{j,1}^{(1)} \cdot x_1 + \dots + W_{j,n}^{(1)} \cdot x_n$$

$$I_j^{(2)} = \sum_{i=0}^n W_{ji}^{(2)} \cdot Y_i^{(1)} \leftrightarrow I_j^{(2)} \quad (2)$$

$$= W_{j,0}^{(2)} \cdot Y_0^{(1)} + W_{j,1}^{(2)} \cdot Y_1^{(1)} + \dots + W_{j,n1}^{(2)} \cdot Y_{n1}^{(1)}$$

$$I_j^{(3)} = \sum_{i=0}^n W_{ji}^{(3)} \cdot Y_i^{(2)} \leftrightarrow I_j^{(3)} \quad (3)$$

$$= W_{j,0}^{(3)} \cdot Y_0^{(2)} + W_{j,1}^{(3)} \cdot Y_1^{(2)} + \dots + W_{j,n2}^{(3)} \cdot Y_{n2}^{(2)}$$

– $Y_j^{(L)}$ são vetores cujo os elementos denotam a saída do j -ésimo neurônio em relação a camada L , os quais são definidos por 4, 5 e 6:

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (4)$$

$$Y_j^{(2)} = g(I_j^{(2)}) \quad (5)$$

$$Y_j^{(3)} = g(I_j^{(3)}) \quad (6)$$

onde g representa uma função de ativação que deve ser contínua e diferenciável em todo o seu domínio.

3.2 Método de Levenberg-Marquardt

O algoritmo *backpropagation* ajusta os valores das matrizes de pesos da rede PMC em relação à direção oposta da função erro quadrático. Entretanto, a utilização deste algoritmo na prática tende a convergir muito lentamente, exigindo-se assim um elevado esforço computacional. Para contornar este inconveniente, várias técnicas de otimização têm sido incorporadas ao algoritmo *backpropagation* a fim de reduzir o seu tempo de convergência e diminuir o esforço computacional requerido.

O algoritmo de Levenberg Marquardt é um método de gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não lineares, que pode ser incorporado ao algoritmo *backpropagation* a fim de potencializar a eficiência processo de treinamento (Silva *et. al.* 2010). Para este algoritmo, as funções erro quadrático e erro quadrático médio, podem ser expressas pelas equações 7, 8 e 9:

$$V = \frac{1}{2p} \sum_{k=1}^p \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (7)$$

$$V = \frac{1}{2p} \sum_{k=1}^p (d(k) - Y^{(3)}(k))^T \cdot (d(k) - Y^{(3)}(k)) \quad (8)$$

$$V = \frac{1}{2p} \sum_{k=1}^p E^T(k) \cdot E(k) \quad (9)$$

o termo $\{E(k) = d(k) - Y^{(3)}(k)\}$ denota o vetor erro em relação a k -ésima amostra de treinamento.

4 Método de tratamento dos dados

A proposta deste trabalho consiste na utilização dos sinais das correntes e das tensões de um MIT no domínio do tempo apresentadas a uma RNA capaz de classificar a existência ou não de falha de rolamento.

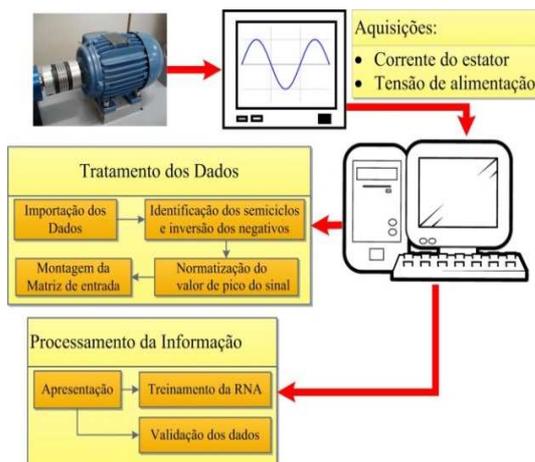


Figura 4. Rotina de aquisição e tratamento dos dados

Diferentemente dos métodos tradicionais de análise de vibração mecânica, que necessitam da instalação de sensores específicos para aquisição dos dados, e mesmo do método proposto por Chow *et al.* (1991) que utiliza os valores eficazes de corrente em cada

amostra e velocidade, esta proposta baseia-se na coleta de dados por um osciloscópio digital de quatro canais isolados modelo TPS 2014 Tecktronix® com ponteiros de tensão X100 e de corrente A622 de 100 Amp AC/DC. A Figura 4 ilustra a rotina de aquisição e tratamento dos dados.

O equipamento possui capacidade de armazenamento dos sinais visualizados em tela em um cartão de memória, onde dados coletados são gravados como planilha de 2.500 pontos para cada fase.

A taxa de amostragem é variável pelo seletor sec/div, o qual é ajustado no equipamento em função do sinal mostrado. De posse dos dados e com uma rotina de importação adequada, estes são manipulados e avaliados no *software* MATLAB®.

4.1 Tratamento dos dados de entrada

Para obter a classificação quanto ao funcionamento adequado do rolamento, foram amostrados os sinais das correntes e tensões trifásicas dos MIT em análise. O sinais foram divididos em 50 pontos por semi-ciclo, e o valor da amplitude de cada ponto apresentado à entrada da RNA, conforme o método proposto por Nascimento *et. al.* (2011).

Tal método considera o sinal de entrada uma forma de onda senoidal no tempo contínuo. Neste sinal, cada semi-ciclo é dividido em um número de amostras necessárias para a composição dos vetores de entrada a serem apresentadas à RNA fazendo assim a discretização linear do sinal, como mostrado na Figura 5.

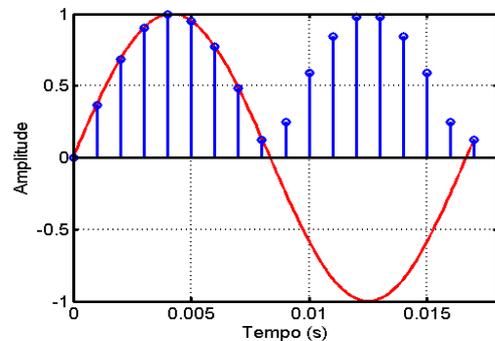


Figura 5. Discretização linear do sinal

Utilizando-se de uma amostragem de 10 ms/div no osciloscópio, obtém-se um total de 12 semi-ciclos de onda amostrados, cada meio-ciclo do sinal. Desta forma uma subamostragem com 50 pontos é capaz de traduzir as informações necessárias sem descaracterizar a forma de onda. Outro aspecto para o tratamento dos dados é o fato de que os sinais são as correntes $(I_{a,b,c})$ e as tensões $(V_{a,b,c})$ de uma máquina trifásica. Assim, faz-se necessário a montagem de um vetor coluna com os pontos de tensões e correntes de cada fase do sistema coletado, subsequentes um do outro.

Como a proposta deste trabalho é ainda a combinação de cinco estruturas na entrada tem-se os vetores de tensão e corrente replicados para cada condição $\{I, V, I^2, V^2, I \times V\}$ montados a partir das condições anteriores, criando assim uma matriz de 750

pontos de entrada pela quantidade de amostras de cada uma das fases.

Em se tratando da utilização de sinais, extraídos de processos industriais reais, correntes e tensões elétricas de máquinas de diferentes potências e diferentes estados de funcionamento, necessita-se realizar a normalização destes dados. Então, foi admitido o valor máximo da tensão e o valor máximo da corrente em cada amostra para esta finalidade.

As análises são realizadas para cada semi-ciclo de onda, então são considerados os valores absolutos dos sinais amostrados tendo apenas os semi-ciclos positivos do sinal, conforme observado na Figura 6, que mostra uma das curvas experimentais normalizadas para amplitude unitária.

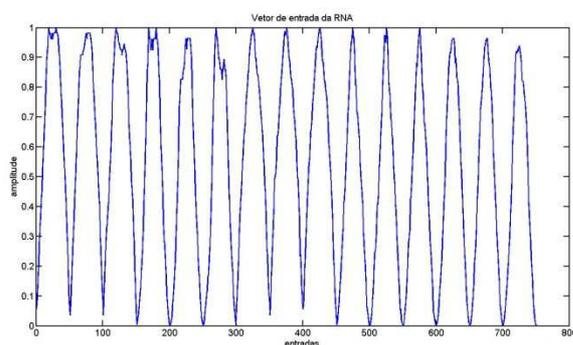


Figura 6. Semi-ciclos positivos do sinal

4.2 Estrutura Neural

A utilização das RNAs tem se mostrado eficiente na resolução de problemas da área de engenharia e projetos, neste caso identificar a existência ou não de falhas em rolamentos de MIT (Faraco *et. al.*, 1998).

Neste trabalho, foi utilizada uma rede *Perceptron* Multicamadas com treinamento supervisionado a partir de um algoritmo de Levenberg Maquardt, com dois neurônios em ambas as camadas oculta e de saída. Para ativação da camada oculta, utiliza-se a função tangente hiperbólica com variação de -1 a 1.

A análise é focada na falha incipiente de rolamentos, sob condições de conjugado de carga constante. As entradas para a Rede 1 foram definidas como a corrente estatórica I e a tensão de alimentação V.

Para a Rede 2, os sinais de corrente e tensão foram combinados em cinco estruturas e apresentados à rede, a corrente elétrica (I), a tensão de alimentação do motor (V), o quadrado da corrente (I^2), o quadrado da tensão (V^2) e o produto destas duas grandezas ($I \times V$). As saídas desejadas são as condições qualitativas (com falha e sem falha), classificadas pela RNA conforme a Tabela 2.

Tabela 2. Resposta da RNA

Saída	Com falha	Sem falha
Y1	-1	1
Y2	1	-1

O algoritmo de treinamento aplica o gradiente baseado no método dos mínimos quadrados para modelos não lineares que, quando incorporado ao processo de

treinamento, potencializa a eficiência dos ajustes dos pesos sinápticos.

As características e topologias de ambas as redes são descritas na Tabela 3.

Tabela 3. Parâmetros das RNA

Tipo	Rede 1	Rede 2
Arquitetura	PMC	PMC
Treinamento	S	S
Nº de camadas	2	2
Neurônios 2º camada	2	2
Neurônios 3º camada	2	2
Algoritmo de treinamento	LM	LM
Função de ativação 2º camada	TH	TH
Função de ativação 3º camada	TH	TH
Função de ativação saída	Linear	Linear

(S) Supervisionado; (LM) LevenbergMaquardt; (TH) Tangente Hiperbólica

Para trabalhar com as redes propostas somente com informações das máquinas em aplicações reais, sem resultados de simulações, separam-se os vetores de amostras coletados dos motores aleatoriamente em duas classes; uma de treinamento e outra de validação, sendo as mesmas divididas conforme Tabela 4. Desta forma, os dados utilizados no treinamento da rede não são apresentados para a validação, permitindo assim a avaliação da sua capacidade de generalização e resposta real do sistema.

Tabela 4. Divisão dos dados coletados

Classes	(%)	Amostras
Amostras de treinamento	68	17
Amostras de validação	32	8

4.3 Resultados da classificação

As redes propostas foram submetidas ao treinamento com os sinais de entrada conforme descrito no item 4.1, com uma taxa de aprendizagem de $\eta = 0,01$. Como critério de parada, foi estabelecido o erro quadrático médio (EQM) de $5 \cdot 10^{-5}$.

A Rede 1 atingiu o critério de parada com 10 épocas, obtendo 75% de acerto. A Rede 2 possui a mesma estrutura que a Rede 1, no entanto, esta rede atingiu o critério de parada com 8 épocas. Na validação, foi obtido 100% de acerto, comprovando a capacidade de generalização da rede, como pode ser observado na Tabela 5.

Tabela 5. Resultados

Tipo	Rede 1	Rede 2
Amostra de treinamento	17	17
Amostra de validação	8	8
EQM	$5 \cdot 10^{-5}$	$5 \cdot 10^{-5}$
Coefficiente de aprendizado	0,01	0,01
Épocas	10	8
Falso positivo	0	0
Falso negativo	2	0
Erro classificação	2/8	0/8
Percentual de acerto	75%	100%

5 Conclusões

Neste trabalho foi apresentado um estudo comparativo entre duas estruturas neurais com o objetivo de classificar, a partir dos sinais de corrente e tensão no domínio do tempo, a ocorrência de falhas incipientes de rolamentos. Tal proposta propicia a indicação de falhas e a correta tomada de decisão em tempo real sem a necessidade de se recorrer a métodos convencionais de análise.

A combinação dos dados de entrada permite incrementar a eficiência computacional. Os resultados obtidos utilizando este artifício possibilitam o aumento da confiabilidade e de acerto em 100% dos casos, o que pode ser considerado satisfatório em aplicações reais.

A aplicação desta rotina pode ser utilizada em motores de variadas potências e em diversos regimes de operação.

Agradecimentos

Os autores agradecem à Destilaria Americana S.A. (DASA) pela disponibilização dos maquinários em que foram realizadas as coletas dos dados.

Referências Bibliográficas

- Araújo, R. S., Rodrigues, R., Paula, H. e Baccharini, L. (2010). *Desgaste prematuro e falhas recorrentes dos rolamentos de um mit: Estudo de caso*, Industry Applications (INDUSCON), 2010 9th IEEE/IAS International Conference on, pp. 1-6.
- Araújo, R., Rodrigues, R., Paula, H. e Baccharini, L. (2011). *Premature wear and recurring bearing failures in three-phase induction motors: a case study*, IEEE Latin America Transactions, vol 9, nº 4, July 2011, pp. 528-533.
- Baccharini, L. M. R. (2005). *Deteção e diagnóstico de falhas em motores de indução*, Tese de Doutorado, Universidade Federal de Minas Gerais.
- Bellini, A., Filippetti, F., Tassoni, C., Capolino, G. A. (2008). *Advances in diagnostic techniques for induction machines*. IEEE Transactions on Industrial Electronics, vol. 55, nº 12, pp. 4109-4126.
- Chow, M.-Y., Mangun, P. M., Yee, S. O. (1991). *A neural network approach to real-time condition monitoring of induction motors*. IEEE Transactions on Industrial Electronics, vol. 38, nº 6, pp. 448-453.
- Eletrobrás (2012). <<http://www.eletrobras.com>>. Acesso em: 05 Jun. 2012.
- Faraco, R. A. L., Costa, P. P. J., Cruz, F. R. B. (1998). *Minimização do erro no algoritmo-Backpropagation aplicado ao problema de manutenção de motores*, Pesquisa Operacional v.18, nº 1, pp. 21-36.
- Ghate, V. e Dudul, S. (2009). *Fault diagnosis of three phase induction motor using neural network techniques*, Emerging Trends in Engineering and Technology (ICETET), 2009 2nd International Conference on, pp. 922-928.
- Han, T., Yang, B.-S. e Yin, Z.-J. (2007). *Feature-based fault diagnosis system of induction motors using vibration signal*, Journal of Quality in Maintenance Engineering, Vol. 13, pp. 163-175.
- Haykin, S. (2001). *Redes Neurais: Princípios e Práticas*, 2ª edição, Porto Alegre: Bookman.
- Kowalski, C. T. e Orłowska-Kowalska, T. (2003). *Neural networks application for induction motor faults diagnosis*, Mathematics and Computers in Simulation 63(3-5): 435-448.
- Nascimento, C. F., Oliveira Jr., A. A., Goedel, A. e Serni, P. J. A. (2011). *Harmonic identification using parallel neural networks in single-phase systems*, Applied Soft Computing 11(2): 2178-2185.
- Rosenblatt, F. (1958). *The perceptron: A probabilistic model for information storage and organization in the brain*, Psychological Review 65(3): 386-408.
- Santos, T. H., Goedel, A., Silva, S. e Suetake, M. (2011). *A neural speed estimator in three-phase induction motors powered by a driver with scalar control*, Power Electronics Conference (COBEP), 2011 Brazilian, pp. 44-49.
- Sayouti, Y., Abbou, A., Akherraz, M. e Mahmoudi, H. (2011). *Sensor less low speed control with ann mras for direct torque controlled induction motor drive*, Power Engineering, Energy and Electrical Drives (POWERENG), 2011 International Conference on, pp. 1-5.
- Seera, M., Lim, C. P., Ishak, D. e Singh, H. (2012). *Fault detection and diagnosis of induction motors using motor current signature analysis and a hybrid fmm - cart model*, Neural Networks and Learning Systems, IEEE Transactions on 23(1): 97-108.
- Silva, I. N., Spatti, D. H. e Flauzino, R. A. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas*, 1ª edição, São Paulo: Artliber.