

DIAGNÓSTICO INTELIGENTE DE FALHAS NO ROTOR, ESTATOR E ROLAMENTO EM MOTORES DE INDUÇÃO TRIFÁSICOS

RODRIGO H. C. PALÁCIOS* IVAN N. DA SILVA† ALESSANDRO GOEDEL* WAGNER F. GODOY*
PEDRO P. D. DA SILVA* GUSTAVO H. BAZAN*

* *Universidade Tecnológica Federal do Paraná, Departamentos de Engenharia Elétrica e Computação
Cornélio Procópio, Paraná, Brasil*

† *Universidade de São Paulo, EESC, Departamento de Engenharia Elétrica
São Carlos, São Paulo, Brasil*

rodrigopalacios@utfpr.edu.br insilva@sc.usp.br agoedel@utfpr.edu.br
wagnergodoy@utfpr.edu.br pedro.petri@hotmail.com gu.bazan@gmail.com

Abstract— This work proposes a methodology for intelligent identification of defects in TIMs through discretization technique of currents and voltages in the time domain and using three types of pattern classifiers: artificial neural network type multilayer perceptron (ANN/MLP), algorithm k-nearest neighbors (*k*-NN) and support vector machine with sequential minimal optimization (SVM/SMO). The investigated faults are related to short-circuit the stator coils, broken bars of the rotor and bearing defects. Experimental results are tested with data gathered from an experimental workbench contemplating various supply conditions and under a wide load variation with a 736 W motor, considering the analysis of the currents and voltages signals amplitudes in the time domain. It is also observed that the MLP and *k*-NN classifiers are highlighted with accuracy above 89%.

Keywords— Three-phase Induction Motors (TIMs), Fault Diagnosis, Pattern Recognition

Resumo— Este trabalho propõe uma metodologia para identificação inteligente de defeitos em motores de indução trifásicos por meio da técnica de discretização dos sinais das correntes e tensões no domínio do tempo, com a aplicação de três tipos de classificadores de padrões: rede neural artificial do tipo *multilayer perceptron* (RNA/MLP), algoritmo *k-nearest neighbors* (*k*-NN) e *support vector machine* com *sequential minimal optimization* (SVM/SMO). Os defeitos observados são relacionados a curto-circuitos nas bobinas do estator, barras quebradas no rotor e defeitos nos rolamentos. Resultados experimentais foram obtidos a partir de dados oriundos de uma bancada experimental de ensaios, contemplando várias condições de alimentação elétrica senoidal e ampla variação da carga mecânica do MIT com potência de 1 cv, proporcionando a análise das amplitudes dos sinais das correntes e tensões no domínio do tempo. Observa-se ainda que os classificadores MLP e *k*-NN se destacaram com resultados de acurácia acima de 89%.

Palavras-chave— Motor de Indução Trifásico (MIT), Diagnóstico de Falhas, Reconhecimento de Padrões

1 Introdução

Os motores de indução trifásicos (MITs) são frequentemente utilizados na indústria devido a sua praticidade e características de baixo custo, baixa manutenção e operação com uma fonte de energia facilmente disponível (Palácios, Goedel, Godoy and Fabri, 2016). Este tipo de motor é considerado o principal equipamento de transformação de energia elétrica em mecânica motriz (Godoy et al., 2016).

Devido ao uso generalizado de automação na indústria e consequente redução da interface direta homem-máquina para supervisionar operações nos sistemas, o monitoramento das condições de motores tem grande importância no processo. A observação permanente do funcionamento das máquinas é importante para detectar, analisar, prevenir e corrigir problemas. Tal procedimento é usado principalmente para aumentar a disponibilidade da máquina, reduzindo danos operacionais, aumentando a vida útil e a consequente redução de custos (Palácios, da Silva, Goedel and Godoy, 2016).

As falhas que afetam o funcionamento dos

MITs são divididas em dois grupos: elétricas e mecânicas. As falhas elétricas são habitualmente relativas aos problemas no enrolamento do estator, enrolamento do rotor (presentes em alguns modelos de motores), barras quebradas no rotor, anéis quebrados no rotor, conexões, entre outras (Yeh and Demerdash, 2007). As falhas mecânicas, por sua vez, podem ser oriundas de problemas nos rolamentos, excentricidade, desgaste de acoplamento, desalinhamento, conforme relatado por Singh and Kazzaz (2003).

Das falhas citadas na literatura, destacam-se os trabalhos de Kowalski and Orłowska-Kowalska (2003) e Han et al. (2007) que, baseados em pesquisas realizadas pela EPRI (*Electric Power Research Institute*), patrocinado pela General Electric Co. e IEEE (*Institute of Electric and Electronic Engineers*), afirmam que aproximadamente 80% das paradas indesejadas nos motores elétricos são relativas às falhas de rotor, estator e rolamento.

Visando contribuir para o desenvolvimento da área de identificação e monitoramento de falhas em MITs, este trabalho propõe a criação de uma metodologia computacional, testada com os métodos inteligentes Redes Neurais Artificiais

(RNA) do tipo *multilayer perceptron* (MLP), *k-nearest neighbors algorithm* (*k*-NN) e *support vector machines* (SVM) com *sequential minimal optimization* (SMO), que identificam falhas de curto-circuito nos enrolamentos do estator de MITs, defeitos de barras quebradas no rotor, problemas no rolamento e determina o caso de motores sem falhas. Em tais métodos são utilizadas as correntes e as tensões trifásicas da alimentação da máquina, discretizadas no domínio do tempo, como parâmetros de entrada, de acordo com o trabalho de Palácios et al. (2014), considerando ainda uma ampla variação da carga aplicada ao eixo do motor e condições de desequilíbrio assimétrico das tensões.

Este artigo é dividido em seis seções. Na Seção I é apresentada uma introdução e a revisão bibliográfica. Na Seção II são abordadas as preliminares sobre classificadores de padrões. Na Seção III é apresentada metodologia deste trabalho. Na Seção IV são apresentados os resultados experimentais e, na Seção V, as conclusões são realizadas.

2 Preliminares sobre Classificadores de Padrões

Os sistemas inteligentes têm sido desenvolvidos como uma abordagem flexível, os quais podem ser aplicados a vários tipos de problemas na área de máquinas elétricas, em especial aqueles relacionados à identificação de padrões de defeitos.

Os classificadores de padrões abordados neste trabalho são baseados na vizinhança de elementos, vetores de suporte e RNA. Estes métodos são caracterizados por utilizarem dados de treinamento e validação para criar um modelo de classificação, que posteriormente são utilizados para classificar uma nova instância de dados relacionados. Uma breve descrição dos algoritmos abordados neste trabalho são apresentados nas subseções seguintes.

2.1 *k*-NN

O classificador *k*-NN (Aha and Kibler, 1991) é um método não-paramétrico e propõe uma modificação em relação ao algoritmo original, proposto por *Nearest Neighbor* (NN) (Cover, 1968), durante a fase de teste e classificação, em que o algoritmo faz uso dos *k*-vizinhos mais próximos, diferentemente do NN que utiliza-se apenas o vizinho mais próximo.

O método *k*-NN classifica uma amostra de dados de acordo com as distâncias entre a amostra e algumas amostras de treinamento pré-rotuladas. Se a maioria das amostras mais próximas à amostra desconhecida são de uma classe especificada, a amostra será atribuída a essa classe. Neste método, os eixos independentes são divididos em partições (Δ_i). Assim, a função de densidade da pro-

habilidade é avaliada para cada uma destas partições.

Para avaliar a probabilidade de uma amostra de teste, deve-se assumir uma partição centrada em um ponto n_i , fixado para alterações, de tal forma que $n_i(K)$ pontos de dados o colocam nesta partição. Com base neste procedimento, a probabilidade da amostra de teste é avaliada de forma adaptativa, sem qualquer hipótese anterior, exceto K , que é escolhido de acordo com os melhores resultados obtidos no treinamento. A partir do teorema de Bayes, a probabilidade posterior de uma amostra de teste é obtida.

Esta abordagem não necessita da fase de treinamento. Contudo, para classificar uma amostra de teste, todos os pontos de dados dos treinamentos devem ser salvos e as distâncias entre as amostras de teste e todas as amostras de treinamento devem ser calculadas e classificadas. Portanto, os *k*-vizinhos mais próximos são selecionados para tomar a decisão final.

A semelhança, ou proximidade, é definida em termos da distância entre as instâncias. Para isto, há várias medidas de distâncias que podem ser utilizadas para implementar esse classificador, tal como o método da distância Euclidiana.

2.2 SVM/SMO

O SVM são sistemas de aprendizagem de máquina treinados com um algoritmo de otimização matemática. Essa estratégia de aprendizagem, desenvolvida por Vapnik (1995), pode alcançar alto desempenho em aplicações práticas. O treinamento do SVM envolve a otimização de uma função quadrática convexa. Esta otimização é um problema matemático que envolve poucos parâmetros livres necessários para ajustes por parte do usuário.

O processo decisório em problemas de classificação pode ser realizado por intermédio de funções que dividem o espaço de características em regiões com hiperplanos. A função principal do SVM consiste em mapear os dados de entrada em um espaço de características por um mapa não linear. No espaço de características, a função de decisão linear é construída.

A SMO, proposto por Platt (1998), é um algoritmo para resolver o problema de programação quadrática, que surge durante o treinamento do SVM. Esta implementação substitui globalmente todos os valores em falta e transforma atributos nominais para os binários e também normaliza todos os atributos por padrão. Os problemas multiclasse são resolvidos usando classificação em pares com o método de acoplamento em pares (Hastie and Tibshirani, 1998).

2.3 RNA/MLP

De acordo com Palácios et al. (2015), as RNAs são métodos flexíveis que podem ser aplicados em di-

versos tipos de problemas de engenharia e são caracterizadas como modelos computacionais, com propriedades particulares, cujas principais características são: (i) capacidade intrínseca de operação em paralelo; (ii) não há necessidade de conhecimento, *a priori*, de eventuais modelos matemáticos que descrevem o comportamento de determinada aplicação; (iii) sistemas inspirados no cérebro humano e (iv) habilidade de aprender a partir da experiência.

A rede MLP é aquela em que os neurônios são organizados em camadas. A característica principal das redes em camadas é a presença de uma ou mais camadas escondidas, as quais são responsáveis pela extração e armazenamento de conhecimentos associados a alguma aplicação específica.

Neste tipo de rede, o fluxo de dados das entradas para as saídas segue estritamente em uma única direção, isto é, existem apenas ligações entre as saídas dos nós de um nível inferior para as entradas dos nós de um nível superior, não existindo conexões entre os elementos de um mesmo nível. Redes em camadas são utilizadas em várias aplicações, tais como: aproximação de funções, reconhecimento de padrões, otimização de sistemas, controle de processos, entre outras (Silva et al., 2010).

Sinteticamente, o funcionamento de uma RNA do tipo MLP consiste na alimentação de informações (vetores de entrada) partir da camada de entrada da rede, as quais constituem os sinais de entrada, que serão aplicados aos neurônios da segunda camada (1ª camada neural). Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada (2ª camada neural). Finalmente, o conjunto de sinais de saída apresentados pelos neurônios da camada de saída reflete a resposta final da rede em relação ao vetor de entrada fornecido pelos nós fontes da primeira camada.

O treinamento ou processo de aprendizagem de uma RNA consiste em ajustar os pesos sinápticos dos neurônios artificiais de forma que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas. O treinamento supervisionado das RNAs que formam as redes Perceptron utilizadas neste trabalho é baseado no algoritmo de aprendizagem *backpropagation* (Silva et al., 2010). As funções Erro Quadrático e Erro Quadrático Médio, são utilizadas como critérios de desempenho e de parada do processo de treinamento.

3 Metodologia

Os MITs, ao longo de suas vidas úteis, estão suscetíveis à operações de cargas e condições ambientais variadas, ocasionando o desgaste natural de suas partes. A verificação de defeitos nos motores em estágios iniciais proporciona uma melhor pro-

gramação da manutenção, reduzindo-se os custos, podendo evitar uma falha (Bellini et al., 2008). No contexto deste trabalho, as falhas incipientes no estator, rotor e rolamento são analisadas por meio de várias técnicas inteligentes conhecidas na literatura.

Os defeitos considerados neste estudo foram reproduzidos em laboratório e são relacionados ao estator com severidades de curto-circuitos entre espiras de uma bobina com comprometimentos de 1%, 3%, 5% e 10%, no rotor com 1, 2 e 4 quebras de barras consecutivas e 2 diametralmente opostas a outras 2, e defeitos nos rolamentos com problemas nas pistas interna e externa, esferas e desgaste excessivo.

Os dados experimentais foram obtidos diretamente do motor, por meio do uso da bancada de testes apresentada na Figura 1. Os sinais de corrente e tensões são medidos no painel de alimentação da máquina onde placas individuais monitoram as grandezas. Os sinais de $\pm 10V$ disponibilizados pelas placas condicionadoras são subsídios de entrada para a placa de aquisição de dados. As placas de condicionamento de sinais dos sensores Hall modulam as correntes de linha que são repassadas às entradas analógicas da placa de aquisição de dados. Por meio da interface de comunicação USB da placa de aquisição de dados com um computador, as informações de sinais são adquiridas e armazenadas com o uso *software* Matlab. A taxa de aquisição ajustada desta placa é de 25000 pontos por segundo de amostragem e utilizou-se um intervalo de 5 a 15 segundos por ensaio. O torque do motor é medido por um torquímetro de dupla faixa de atuação com sensor de velocidade integrado que permite a leitura de sinais analógicos ou digitais até 50 Nm e 7000 rpm.




Figura 1: Bancada experimental utilizada nos ensaios com o MIT

Todo processo de aquisição e tratamento dos dados amostrais, assim como o processamento do identificador de defeitos, é feito por meio dos reconhecedores de padrões investigados. No módulo de tratamento dos dados, o conjunto de dados com sinais das correntes e tensões de cada fase ($I_{a,b,c}$ e $V_{a,b,c}$) são selecionados a partir do motor

em regime permanente e, então, para cada ensaio, é selecionado meio período de onda de cada fase das correntes e tensões no domínio do tempo. Os dados de cada sinal de corrente são organizados e discretizados em 10, 25 e 50 pontos por semiciclo de onda da corrente por fase (do Nascimento et al., 2011) e são normalizados pelo valor de pico do sinal. Na sequência, são gerados vetores com 60, 150 e 300 pontos (valores absolutos) refletindo o comportamento dos sinais das três fases. A partir de então há duas opções, ou processa-se os dados com 60, 150 e 300 entradas. Tais alternativas são processadas e os resultados são apresentados neste artigo. Para todos os defeitos analisados foram testados 3 métodos inteligentes para a classificação dos padrões com dados originados do motor.

Os classificadores de padrões foram avaliados neste trabalho por meio do ambiente *Waikato Environment for Knowledge Analysis* (WEKA) (Hall et al., 2009). As configurações do computador utilizados no treinamento e validação das amostras consiste em um processador Intel Core i3 380M 2.53 GHz, memória RAM de 4 GB, HD de 500 GB e adaptador gráfico Intel Graphics Media Accelerator (GMA) 4500 MHD.

As configurações básicas do método SVM/SMO determinam que a taxa de erro de arredondamento possui o valor 10^{-12} , a função núcleo do SVM/SMO é a *Polynomial Kernel* (Alpaydin, 2010) e o parâmetro de tolerância de erro recebeu o valor 0,001.

Em relação aos aspectos de configurações da RNA, a taxa de aprendizado foi definida com o valor 0,1, o termo *momentum* recebeu 0,2 e o número máximo de épocas para o treinamento da rede é de 500. Foram utilizados 32, 77 e 152 neurônios na única camada oculta para as respectivas 60, 150 e 300 entradas, definidos pela análise dos resultados e definição da melhor topologia. Para a camada oculta, foi utilizada a função de ativação Tangente Hiperbólica e na camada de saída uma função Linear.

A configuração do método de classificação k -NN para a execução dos testes foi definido com número de vizinhos igual a 3 e o algoritmo de busca utilizado é baseado no método do cálculo da distância Euclidiana.

Para a verificação dos resultados relativos aos testes realizados por meio dos classificadores inteligentes, utilizou-se os índices estatísticos: acurácia, *Kappa*, erro absoluto médio e erro absoluto relativo, além de computar o tempo de construção do modelo e o tempo de validação em segundo.

A acurácia define em termos percentuais o acerto de um conjunto de amostras apresentadas ao classificador em comparação ao padrão previamente definido, a fim de obter a exatidão do modelo testado.

O erro absoluto define a diferença de um valor encontrado pelo valor desejado. No caso de

um conjunto de amostras apresentado ao classificador, tem-se a medida do erro absoluto médio para definir o quão distantes estão as amostras com erros de classificação. O erro absoluto relativo é definido pelo quociente entre o erro absoluto e o módulo do valor exato.

A estatística *Kappa* é um índice que mede o grau de concordância interobservador além do que seria esperado tão somente pelo acaso (Landis et al., 1977). O seu cálculo é baseado nos dados de treinamento dos métodos inteligentes após ser removida a parcela de concordância devido ao acaso. Esta medida de concordância *Kappa* retorna como valor máximo “1”, na qual representa total concordância, sendo que valores próximos e até abaixo de “0” indicam nenhuma concordância.

4 Resultados Experimentais

Os resultados da combinação dos testes do motor sem falhas e com defeitos no rolamentos, no rotor e no estator são apresentados nas Tabelas 1, 2 e 3. Este procedimento combinatório para multiclassificação de defeitos tem como finalidade verificar o quão robusto os métodos inteligentes são e medir as suas capacidades em termos de acurácia, erros e custo computacional. Para tanto, considerou-se inclusive o desequilíbrio das tensões na alimentação da máquina e a variação de carga para um MIT de 1 cv. O total de 960 amostras utilizadas nos testes foram organizadas em 4 classes distintas, para cada situação observada de falhas e sem falhas, no qual foram divididas em 320 amostras com falhas no estator, 320 amostras com falhas de rotor, 240 amostras com falhas de rolamento e 80 amostras com situação do motor sem falhas.

Os dados experimentais foram divididos em dois grupos: treinamento e validação. Para todos os testes, foi utilizado o método conhecido como validação cruzada, com 10 subconjuntos para treinamento e validação. Neste processo, de acordo com Silva et al. (2010), o conjunto amostral original é dividido aleatoriamente em 10 subconjuntos. Dos 10 subconjuntos, um único subconjunto é mantido como a validação dos dados para testar o modelo, os restantes 9 subconjuntos são utilizados como dados de treinamento. O processo de validação cruzada é repetida 10 vezes, com cada um dos subconjuntos. Ao final do processo da validação cruzada, calcula-se então a precisão sobre os erros encontrados, proporcionando uma medida mais confiável sobre a capacidade do modelo classificador.

Na Tabela 1 são apresentados os resultados relativos à entrada dos métodos com 60 entradas (30 pontos das tensões $V_{a,b,c}$ e 30 pontos das correntes $I_{a,b,c}$). É possível observar nesta tabela que os índices de acurácia dos métodos k -NN e RNA/MLP obtiveram valores maiores que 96%, assim como os índices *Kappa* se mantiveram acima de 0,94. Con-

tudo, o m todo SVM/SMO se mostrou abaixo dos demais m todos comparados com valor de acerto pr ximo a 82%, com o  ndice *Kappa* em torno de 0,74, demonstrando-se ainda uma alta confiabilidade nas classifica  es propostas.

Tabela 1: Resultados de treinamento e valida  o para motores de 1 cv com 60 entradas com corrente e tens o para multiclassifica  o de motor sem falhas e com defeitos de estator, rotor e rolamento.

Multiclassifica��o - 60 Entradas			
Classificadores	SVM/SMO	k-NN	RNA/MLP
Entradas ($V_{a,b,c}$, $I_{a,b,c}$)	60	60	60
Acur�cia	82,85%	96,47%	96,02%
Tempo de Constru��o	19,69 s	0,01 s	127,22 s
Tempo de Valida��o	0,02 s	7,54 s	0,09 s
<i>Kappa</i>	0,74	0,95	0,94
Erro Abs. M�dio	0,26	0,02	0,02
Erro Abs. Rel.	76,83%	5,17%	7,10%
Amostras	960	960	960

Na Tabela 2, os resultados referentes   entrada com 150 pontos, divididos em 75 pontos relativo  s tens  es $V_{a,b,c}$ e 75 pontos relacionados  s correntes $I_{a,b,c}$. Os valores resultantes s o aproximados aos testes com 60 pontos de entradas para os m todos observados.

Tabela 2: Resultados de treinamento e valida  o para motores de 1 cv com 150 entradas com corrente e tens o para multiclassifica  o de motor sem falhas e com defeitos de estator, rotor e rolamento.

Multiclassifica��o - 150 Entradas			
Classificadores	SVM/SMO	k-NN	RNA/MLP
Entradas ($V_{a,b,c}$, $I_{a,b,c}$)	150	150	150
Acur�cia	89,24%	95,53%	90,47%
Tempo de Constru��o	77,17 s	0,01 s	1634,34 s
Tempo de Valida��o	0,09 s	19,36 s	0,67 s
<i>Kappa</i>	0,84	0,93	0,86
Erro Abs. M�dio	0,26	0,02	0,05
Erro Abs. Rel.	75,05%	6,52%	14,24%
Amostras	960	960	960

Assim como as verifica   es anteriores para testes de multiclassifica  o de defeitos de estator, rotor e rolamento, o experimento com 300 entradas de valores compostos por tens  es e correntes do motor de 1 cv, os resultados se mostraram coerentes com as avalia   es com entradas de 60 e 150 pontos equidistantes. Na Figura 2, observa-se o gr fico comparativo entre os m todos com as respectivas varia   es de entradas para os m todos SVM/SMO, k-NN e RNA/MLP.

Tabela 3: Resultados de treinamento e valida  o para motores de 1 cv com 300 entradas com corrente e tens o para multiclassifica  o de motor sem falhas e com defeitos de estator, rotor e rolamento.

Multiclassifica��o - 300 Entradas			
Classificadores	SVM/SMO	k-NN	RNA/MLP
Entradas ($V_{a,b,c}$, $I_{a,b,c}$)	300	300	300
Acur�cia	87,52%	89,67%	91,85%
Tempo de Constru��o	20,74 s	0,01 s	7845,76 s
Tempo de Valida��o	0,24 s	7,58 s	0,89 s
<i>Kappa</i>	0,81	0,85	0,87
Erro Abs. M�dio	0,26	0,05	0,06
Erro Abs. Rel.	75,23%	15,09%	15,81%
Amostras	960	960	960

No geral, para situa   es em que ocorrem defeitos combinados em MIT com pot ncia de 1 cv




Figura 2: Desempenho dos m todos avaliados para motor sem falhas e com defeitos no rolamento, rotor e estator combinados do motor de 1 cv (960 amostras para treinamento e valida   o).

com varia   o do n mero de entradas, os m todos k-NN e RNA/MLP apresentaram os melhores  ndices de resultados.

5 Conclus  o

Nesta pesquisa foi apresentada uma metodologia para um sistema de diagn stico de um motor sem falhas e com defeitos no estator, rotor e rolamentos de um MIT, acionado pela rede el trica. Os defeitos considerados s o relacionados ao estator com severidades de curto-circuitos entre espiras de uma bobina com comprometimentos de 1%, 3%, 5% e 10%, no rotor com 1, 2 e 4 quebras de barras consecutivas e 2 diametralmente opostas a outras 2, e defeitos nos rolamentos com problemas nas pistas interna e externa, esferas e desgaste excessivo. No pr -processamento foi utilizado a t cnica de discretiza   o dos sinais de correntes e tens  es no dom nio do tempo. Esta t cnica consiste na constru   o de um vetor com pontos equidistantes de um semi-ciclo de onda. Este conjunto de pontos caracterizam o comportamento do motor e possibilitam que os m todos classificadores criem um modelo padr o para identifica   o do problema relacionado ao estado da m quina.

Os valores das amplitudes dos sinais $I_{a,b,c}$ e $V_{a,b,c}$, em forma de vetor com 60, 150 e 300 posi   es, alimentaram os reconhecedores de padr  es abordados neste trabalho. Todos os tipos de classificadores testados tiveram as suas configura   es variadas a fim de buscar a melhor performance na identifica   o das falhas.

Para a RNA/MLP, os resultados de acur cia se mostraram de forma geral acima de 90% e os demais  ndices estat sticos se mostraram promissores. O m todo k-NN, no geral, apresentou resultados de acur cia acima de 89% e estat stica *Kappa* acima de 0,85. Contudo, o algoritmo SVM/SMO apresentou  ndices de at  89,24%, demonstrando resultados inferiores aos demais m todos comparados. Os m todos RNA/MLP e o SVM/SMO apresentaram os melhores comportamentos no caso da utiliza   o de 60 valores de en-

tradas, inferindo positivamente no sentido da redução do custo computacional.

Referências

- Aha, D. and Kibler, D. (1991). Instance-based learning algorithms, *Machine Learning* **6**: 37–66.
- Alpaydin, E. (2010). *Introduction to Machine Learning*, 2nd edn, The MIT Press.
- Bellini, A., Filippetti, F., Tassoni, C. and Capolino, G. A. (2008). Advances in diagnostic techniques for induction machines, *IEEE Transactions on Industrial Electronics* **55**(12): 4109–4126.
- Cover, T. (1968). Estimation by the nearest neighbor rule, *IEEE Transactions on Information Theory* **14**(1): 50–55.
- do Nascimento, C. F., de Oliveira Jr, A. A., Goedtel, A. and Serni, P. J. A. (2011). Harmonic identification using parallel neural networks in single-phase systems, *Applied Soft Computing* **11**(2): 2178–2185.
- Godoy, W. F., da Silva, I. N., Goedtel, A., Palácios, R. H. C. and Lopes, T. D. (2016). Application of intelligent tools to detect and classify broken rotor bars in three-phase induction motors fed by an inverter, *IET Electric Power Applications* **1**(1): 1–10.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P. and Witten, I. H. (2009). The weka data mining software: An update, *SIGKDD Explor. Newsl.* **11**(1): 10–18.
- Han, T., Yang, B.-S. and Yin, Z.-J. (2007). Feature-based fault diagnosis system of induction motors using vibration signal, *Journal of Quality in Maintenance Engineering* **13**(2): 163–175.
- Hastie, T. and Tibshirani, R. (1998). Classification by pairwise coupling, *Proceedings of the 1997 Conference on Advances in Neural Information Processing Systems 10*, NIPS '97, MIT Press, Cambridge, MA, USA, pp. 507–513.
- Kowalski, C. T. and Orłowska-Kowalska, T. (2003). Neural networks application for induction motor faults diagnosis, *Mathematics and Computers in Simulation* **63**(3-5): 435–448.
- Landis, J. R., Koch, G. G. et al. (1977). The measurement of observer agreement for categorical data, *biometrics* **33**(1): 159–174.
- Palácios, R. H. C., da Silva, I. N., Goedtel, A. and Godoy, W. F. (2016). A novel multi-agent approach to identify faults in line connected three-phase induction motors, *Applied Soft Computing* **45**: 1 – 10.
- Palácios, R. H. C., da Silva, I. N., Goedtel, A., Godoy, W. F. and Lopes, T. D. (2015). Reconhecedor neural de defeitos no estator em motores de indução trifásicos apoiado por análise de componentes principais, *XII Simpósio Brasileiro de Automação Inteligente (SBAI)*, SBA, pp. 1206–1211.
- Palácios, R. H. C., da Silva, I. N., Goedtel, A., Godoy, W. F. and Oleskovicz, M. (2014). A robust neural method to estimate torque in three-phase induction motor, *Journal of Control, Automation and Electrical Systems* **25**(4): 493–502.
- Palácios, R. H. C., Goedtel, A., Godoy, W. F. and Fabri, J. A. (2016). Fault identification in the stator winding of induction motors using pca with artificial neural networks, *Journal of Control, Automation and Electrical Systems* pp. 1–13.
- Platt, J. (1998). Fast training of support vector machines using sequential minimal optimization, in B. Schoelkopf, C. Burges and A. Smola (eds), *Advances in Kernel Methods - Support Vector Learning*, MIT Press.
- Silva, I. N., Spatti, D. H. and Flauzino, R. A. (2010). *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas*, ArtLiber, São Paulo.
- Singh, G. and Kazzaz, S. A. S. A. (2003). Induction machine drive condition monitoring and diagnostic research - a survey, *Electric Power Systems Research* **64**(2): 145–158.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*, Springer-Verlag New York, Inc., New York, NY, USA.
- Yeh, C. C. and Demerdash, N. A. O. (2007). Induction motor-drive systems with fault tolerant inverter-motor capabilities, *IEEE International Electric Machines Drives Conference*, Vol. 2, pp. 1451–1458.