

SISTEMAS INTELIGENTES APLICADOS NA ESTIMAÇÃO DE FALHAS DE ROLAMENTOS EM MOTORES DE INDUÇÃO TRIFÁSICOS ALIMENTADOS POR INVERSORES DE FREQUÊNCIA

WAGNER F. GODOY* IVAN N. DA SILVA† ALESSANDRO GOEDEL* RODRIGO H. C. PALÁCIOS*
DANIEL MORÍNIGO-SOTELO‡ ÓSCAR DUQUE-PÉREZ‡

**Universidade Tecnológica Federal do Paraná, Depto. de Engenharia Elétrica
Av. Alberto Carazzai, 1640, Centro, 86.300-000
Cornélio Procopio, PR, Brasil*

†*Universidade de São Paulo, Escola de Engenharia de São Carlos, Depto. de Engenharia Elétrica
Av. Trabalhador São Carlense, 400, Centro, 13.566-590
São Carlos, SP, Brasil*

‡*Universidade de Valladolid, Depto. de Engenharia Elétrica
Paseo del Cause s/n, 47011
Valladolid, Espanha*

Email: wagnergodoy@utfpr.edu.br, insilva@sc.usp.br, agoedel@utfpr.edu.br,
rodrigopalacios@utfpr.edu.br, dmorinigo@hspdigital.org, oscar.duque@eii.uva.es

Abstract— This paper proposes an approach based on intelligent systems for the classification and diagnosis of bearing fault evolution in inverter-fed induction motors, operating at steady state under a wide range of frequencies and load torque. Due to its robustness and low cost, induction motors are used in various industrial applications. In this work, the classifiers multilayer perceptron (MLP) and k -nearest neighbours (k -NN) are used for the diagnosis and classification of bearing faults. Results obtained from 1173 experimental tests collected in the laboratory are presented to validate this proposal. The obtained results shows that this approach can accurately classify healthy and bearing defects in inverter-fed induction motors.

Keywords— Intelligent system, Induction motor, Diagnosis, Bearing faults

Resumo— Este trabalho propõe uma abordagem baseada em sistemas inteligentes para classificação e diagnóstico de evolução de uma falha de rolamento em motores de indução alimentados por inversores de frequência, operando em regime permanente, em uma ampla faixa de frequências e conjugado de carga. Devido à sua robustez e baixo custo, os motores de indução são utilizados nas mais diversas aplicações industriais. Neste trabalho, os classificadores perceptron multicamadas (PMC) e k -vizinhos mais próximos (k -NN) são utilizados para o diagnóstico e classificação de falhas de rolamentos. Resultados experimentais obtidos a partir de 1173 ensaios de laboratório são apresentados para validar esta proposta. Os resultados obtidos demonstram que é possível classificar com precisão motor saudável e motor com falhas de rolamentos em motores de indução alimentados por inversores, a partir da amplitude dos sinais de corrente no domínio do tempo.

Palavras-chave— Sistemas Inteligentes, Motor de indução, Diagnóstico, Falhas de rolamentos

1 Introdução

Os motores de indução trifásicos (MIT) são amplamente utilizados em grande parte das aplicações industriais devido à sua construção simples, robustez, elevada confiabilidade, e mais recentemente devido à possibilidade de emprego de inversores de frequência, em que diferentes estratégias de controle eficientes podem ser aplicadas nestas máquinas (Bellini et al., 2008). Assim, estas máquinas estão presentes em muitas aplicações nos mais diversos processos industriais.

As máquinas elétricas estão sujeitas às falhas elétricas ou mecânicas. As falhas elétricas são destacadas devido aos problemas relativos ao enrolamento de estator, o enrolamento de rotor, as barras quebradas no rotor, os anéis quebrados no rotor e conexões. Por outro lado, as falhas mecânicas podem ser oriundas de problemas de rolamentos, excentricidade, desgaste de acoplamento e desalinhamento, conforme (Bellini et al., 2008).

Na indústria, muitos processos requerem variações de velocidade, ocasionando significativas alterações no perfil de acionamento de cargas ao longo da última década. Assim, busca-se o aumento da eficiência energética, da qualidade de energia elétrica, do cumprimento de requisitos legais, bem como na geração de benefícios aos próprios usuários. Assim, o monitoramento das condições de operação destas máquinas atingiu significativa relevância, à medida que os mesmos fazem parte importante de muitos processos industriais (Ghorbanian and Faiz, 2015).

Embora estes motores sejam usualmente bem construídos e robustos, a possibilidade de falhas é inerente à operação do dispositivo. Defeitos incipientes dentro da máquina geralmente afetam seu desempenho antes mesmo que falhas significativas ocorram, trazendo assim prejuízos ao processo industrial. A aplicação de metodologias de diagnóstico confiável permite a manutenção eficaz e consequente redução de custos operacionais

(Seera et al., 2014). Diversos métodos para diagnóstico de falhas são utilizados nas áreas de manutenção e proteção de MIT (Ghorbanian and Faiz, 2015; Riera-Guasp et al., 2015).

Dentre as diversas causas de falhas em MIT, os problemas de rolamentos são responsáveis por 50% à 90% das causas associadas a paradas indesejadas de motores elétricos (Bellini et al., 2008; Riera-Guasp et al., 2015). A origem destas falhas estão comumente associadas às assimetrias rotóricas, mas podem também ser oriundas dos anéis internos, dos anéis externos ou dos elementos girantes do rolamento (Riera-Guasp et al., 2015). O desenvolvimento e a evolução deste tipo de falha ocorre principalmente devido à vibração, desgaste interno, desalinhamento do eixo, excentricidade, corrente no rolamento, poeira, corrosão, lubrificação inadequada, além da sua montagem incorreta (Araújo, 2011).

Falhas neste componente podem ser diagnosticadas de forma não-invasiva por intermédio do monitoramento quantitativo de variáveis como vibração, corrente, temperatura, velocidade entre outros (Bellini et al., 2008; Yilmaz and Ayaz, 2009; Abu-Rub et al., 2010). Especificamente, no caso dos MIT acionados por inversores de frequência, a deterioração dos rolamentos podem ser associadas as correntes de modo comum, que circulam pelos rolamentos em função da carga eletrostática induzida no eixo do motor, as oscilações de conjugado devido às barras quebradas no rotor ou em função dos harmônicos de corrente de baixa ordem (Muetze and Binder, 2007).

Em Seera et al. (2012), o diagnóstico e a detecção de falhas em MIT utiliza o perfil do sinal de corrente do motor. Tais técnicas utilizam uma combinação de métodos de monitoramento das condições elétricas e mecânicas da máquina. O monitoramento da assinatura de corrente é frequentemente implementado com menor custo em máquinas de diferentes tamanhos e potências devido ao seu fácil controle mediante a utilização de transformadores de corrente, dispensando a instalação de sensores adicionais.

Estratégias baseadas em sistemas inteligentes também têm sido aplicadas na identificação de falhas de rolamentos (Jia et al., 2016). No artigo de (Yilmaz and Ayaz, 2009) é utilizado um sistema composto por três modelos ANFIS para detecção de falhas de rolamentos em motores de indução tendo como entradas para cada modelo os dados de corrente, vibração e temperatura.

Ainda no trabalho de Abu-Rub et al. (2010) é utilizado um modelo ANFIS para o diagnóstico de falhas incipientes de rolamentos em motores de indução trifásicos acionados por inversores de frequência por meio de simulações. Como entradas foram consideradas a distorção harmônica total do espectro de corrente do estator, a velocidade da máquina e as condições de carga.

Em Onel et al. (2009) é descrita a utilização de uma rede de Funções de Base Radial (*Radial Basis Function* - RBF) para detecção automática de falhas de rolamentos em um motor alimentado por um inversor de frequência utilizando a transformada Concórdia.

Também são utilizadas as abordagens baseadas na análise de vibração para a determinação de falhas em rolamentos. Entre estas pode-se citar o trabalho de Araújo (2011), onde são analisadas as possíveis causas de falhas prematuras em rolamentos dos MIT acionados por inversores, contextualizada no estudo de um caso real.

Devido à relevância deste componente no contexto de falhas, as pesquisas direcionam o diagnóstico de forma não-invasiva por meio do monitoramento de variáveis como vibração, temperatura, e especialmente mediante os sinais de corrente associados a sistemas inteligentes como ferramenta de suporte à identificação (S. and Hegde, 2016).

Assim, a abordagem proposta neste trabalho considera a aplicação dos classificadores PMC e *k*-NN para o diagnóstico e estimação do nível de severidade de uma falha de rolamento em um MIT alimentado por diferentes modelos de inversores de frequência, tendo como parâmetros de entrada as amplitudes dos sinais de corrente do estator, no domínio do tempo. As estruturas foram treinadas e validadas por meio de um conjunto composto por 1173 ensaios experimentais, coletados em uma ampla faixa de frequência e conjugado de carga. Como resultado, será investigada a evolução de uma falha de rolamento, contribuindo com os estudos relacionados a predição de falhas e a tomada de decisão em relação parada da máquina.

Este artigo está organizado da seguinte forma: a Seção 2 resume os aspectos gerais relativos as estratégias de classificação recentemente empregadas na literatura. Na Seção 3, tem-se a metodologia proposta para geração da falha, tratamento dos dados e parâmetros de configuração empregados nos classificadores. Os resultados experimentais são apresentados na Seção 4. Finalmente, na Seção 5, as conclusões finais do trabalho são apresentadas.

2 Estratégias de Classificação

Trabalhos recentes apresentam avanços na pesquisa de técnicas relacionadas ao diagnóstico de falhas utilizando ferramentas inteligentes, conforme observado nas pesquisas de (Seera et al., 2014; Riera-Guasp et al., 2015). Muitos pesquisadores têm sugerido uma série de técnicas de diagnóstico de falhas incluindo modelagem, sistemas especialistas e sistemas de confiabilidade, como pode ser visto em Jia et al. (2016) e Seera et al. (2014). Todos estes métodos apresentam suas próprias vantagens e satisfazem algumas necessidades práticas, no entanto, é essencial que estes sistemas

incorporem as habilidades de monitorar as condições de operação em tempo real.

Sistemas baseados em redes neurais possuem elevadas taxas de computação por utilizarem um número elevado de elementos processadores simples, massivamente conectados. A rede utilizada no desenvolvimento deste trabalho é a rede PMC. A característica principal deste tipo de rede é a presença de uma ou mais camadas escondidas, as quais são responsáveis pela extração e armazenamento de conhecimentos associados a alguma aplicação específica (Han et al., 2011).

A estrutura neural proposta é utilizada 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 (Han et al., 2011). Seu treinamento é realizado de forma supervisionada, fazendo com que a rede ajuste adequadamente os pesos para melhor atender os objetivos.

O algoritmo k -NN é um método não-paramétrico, baseado na aprendizagem por analogia, ou seja, por meio da comparação de similaridades entre um determinado conjunto de teste com o seu respectivo conjunto de treinamento (Han et al., 2011; Duda et al., 2001). Os conjuntos de treinamento são descritos por n atributos. Cada dado representa um ponto em um espaço n -dimensional, desta forma, todos os dados de treinamento são armazenados em um espaço padrão n -dimensional. Neste algoritmo, os conjuntos de treinamento são armazenados em um espaço padrão, onde aguardam a apresentação do conjunto de testes antes de executar a generalização (Han et al., 2011; Duda et al., 2001). Um estudo completo sobre estruturas utilizadas neste trabalho pode ser encontrado em (Han et al., 2011; Duda et al., 2001).

Na Seção 3, são discutidos os aspectos relacionados a metodologia de inserção das falhas, bem como a descrição dos procedimentos de tratamento e discretização dos sinais das correntes, utilizadas como entradas dos classificadores, além de apresentar os resultados experimentais.

3 Metodologia

Os rolamentos do motor de indução trifásico são os elementos que apresentam o maior índice de falhas associadas a paradas indesejadas de motores elétricos (Bellini et al., 2008; Riera-Guasp et al., 2015). Este tipo de falha é associada a causas tais como: desalinhamento da máquina, montagem incorreta do rolamento, contaminação, corrosão, lubrificação insuficiente ou excessiva, sobrecarga mecânica, entre outras (Muetze and Binder, 2007; Onel et al., 2009).

A metodologia proposta considera a utilização dos sinais das amplitudes das correntes do estator,

no domínio do tempo, apresentadas como entrada dos classificadores, visando estimar o nível de evolução de uma falha de rolamento. Neste trabalho, foi utilizado um MIT de 1 CV, 60 Hz, 220/380 V, 3,02/1,75 A, 4 pólos, 4,1 N.m e 1730 rpm. O MIT foi acionado por três inversores de frequência distintos (Siemens Sinamics G110, Siemens Micromaster 440 e Schneider ATV12H075M2) visando a validação da estratégia proposta para diferentes modelos e marcas de inversores comerciais.

A frequência síncrona de cada um dos inversores foi variada de 12 Hz a 60 Hz, em intervalos de 6 Hz. Para cada valor de frequência, variou-se o torque de carga de 0.5 N.m a 5.0 N.m, com intervalos de 0.5 N.m. para cada experimento, visando avaliar o método em função da dependência de carga e da frequência de operação.

A literatura consultada mostra que alguns trabalhos científicos, tais como S. and Hegde (2016), utilizam procedimentos artificiais de inserção de falhas buscando controlar as diversas variáveis e assim tentar reproduzir as características associadas as falhas de rolamentos. Assim, a abordagem para inserção de falha de rolamentos utilizada neste trabalho considera a evolução progressiva do desgaste de um rolamento causada pela contaminação da lubrificação durante a montagem, buscando assim a similaridade do processo de desgaste do rolamento pelo uso excessivo, lubrificação inadequada e excesso de carga no eixo, fatores estes que conduzem o rolamento a sua consequente degradação.

Para os testes foi utilizado o rolamento rígido de esferas, modelo NSK 6204 2Z. O banco de dados compreende 1173 testes experimentais realizados sob diferentes condições de velocidade e conjugado de carga.

A configuração da bancada de ensaios é mostrada na Figura 1, em que um motor de indução pode ser alimentado de forma direta ou por um inversor de frequência.



Figura 1: Bancada experimental de ensaios

Os dados adquiridos são armazenados em forma de planilhas utilizando o *software* Matlab[®], sendo armazenados dados de tensões, correntes, velocidade e torque. A taxa de aquisição considerada para todos os testes foi de 25.000 amostras/s,

e um tempo de aquisição de 6 segundos.

Inicialmente, foram aquiridas todas as amostras do motor operando com rolamento sem defeitos. Para execução destes na condição rolamento com defeito, foi efetuada a substituição do lubrificante por pasta abrasiva, marca Brasillex, composta de carbono, silício, graxa e óleo, conforme a Figura 2. Foram consideradas 4 situações distintas de desgaste, a saber: desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Para a geração de cada um destes níveis de desgaste, foram utilizados conjuntos de rolamentos novos, em que após a remoção das blindagens de proteção lateral os rolamentos foram contaminados com pasta abrasiva. Na sequência, o motor foi acionado diretamente na rede operando a vazio de forma ininterrupta para cada um dos períodos de desgaste definidos, como segue: 15, 30, 60 e 90 minutos, respectivamente.

Durante o período de desgaste, foram monitoradas as correntes de estator e a temperatura da máquina visando assegurar a correta operação da máquina. Uma vez concluído o período definido de desgaste, os rolamentos foram retirados e lavados com solvente visando completa remoção de quaisquer resíduos da pasta abrasiva. Uma vez limpos, os rolamentos foram secos com ar comprimido, novamente lubrificados e montados nas máquinas para sequência dos ensaios e aquisição de sinais. Após cada processo de desgaste, visualmente é perceptível a formação de folgas entre as partes componentes do rolamento, característica esta similar a observada nas peças com desgaste excessivo por falta de lubrificação.



Figura 2: Contaminação do rolamento dianteiro com pasta abrasiva

3.1 Tratamento dos dados de entrada

Considerando que um motor em operação com falhas apresenta um sinal característico ao longo do tempo, a fim de otimizar o conjunto de dados, três semi-ciclos do sinal positivo são aleatoriamente escolhidos para representar cada experimento. Os sinais de corrente são normalizados pelo seu valor de pico. Este procedimento garante que estes dados possam ser utilizados independente do nível

de carga ou de frequência.

Assim, 50 pontos por semi-ciclo de cada sinal de corrente (I_a , I_b e I_c) são extraídos, bem como o valor da amplitude de cada ponto das correntes do estator são apresentados como entradas para os algoritmos de classificação, a partir da discretização linear do sinal, que é capaz de traduzir a informação necessária sem descaracterizar a forma de onda, seguindo o método proposto por do Nascimento et al. (2011).

Como os sinais representam as correntes de estator, faz-se necessário a montagem de um vetor coluna com pontos adquiridos sequencialmente para cada uma das fases do sistema, criando uma matriz de entrada de 150 pontos.

3.2 Estruturas de Classificação

Foram implementadas diferentes estratégias inteligentes de classificação, escolhidas com base nos métodos recentemente aplicados na classificação de falhas em MIT (Seera et al., 2014; Jia et al., 2016).

Os dados são aleatoriamente apresentados as estruturas de classificação, de tal forma que os algoritmos de preparação dos dados garantam que as amostras apresentadas representem todo o domínio de operação do motor. Os dados experimentais foram divididos em dois grupos: treinamento e validação.

Os conjuntos de aprendizado foram submetidos para execução na ferramenta WEKA (*Waikato Environment for Knowledge Analysis*), é uma ferramenta de KDD - *Knowledge Discovery in Databases* que contempla uma série de algoritmos de preparação de dados e aprendizagem de máquina.

O algoritmo de treinamento da rede PMC é o *backpropagation*, que tem a função de encontrar as derivadas da função de erro com relação aos pesos e bias da RNA. Neste trabalho, os melhores resultados foram estabelecidos quando foram utilizados 76 neurônios na camada intermediária. Conforme (Godoy et al., 2014) observa-se que a função de ativação tangente hiperbólica na camada intermediária e função de ativação linear na camada de saída apresentaram os melhores resultados. O parâmetro taxa de aprendizado apresenta forte influência sobre o tempo de treinamento, e neste trabalho este parâmetro foi definido como 0,2.

Para a definição da configuração do número de vizinhos para o método k -NN foram realizados testes considerando uma variação de 1 até 15 vizinhos. No entanto, observou-se os melhores resultados quando foram estabelecidos $1 \leq k \leq 4$. Assim, a configuração do classificador k -NN foi definida como sendo apenas 1 vizinho utilizado. O algoritmo de busca utilizado é baseado no método de cálculo da distância Euclideana.

Para treinamento e validação dos classificadores, utiliza-se o método de validação cruzada

(k -partições), utilizando $k = 10$. Para cada condição, foram escolhidos aleatoriamente ($k - 1$) subconjuntos de treinamento, e o teste realizado com o subconjunto remanescente.

4 Resultados experimentais

As estratégias de classificação propostas foram submetidas ao treinamento utilizando as amplitudes dos sinais das correntes trifásicas, onde cada ponto é apresentado como uma entrada para os classificadores, resultando assim em 3 amostras referentes a cada ensaio experimental realizado.

As Tabelas 1 e 2 apresentam os resultados de classificação do conjunto composto por 1173 ensaios experimentais resultando em 3519 amostras utilizadas para treinamento e validação dos classificadores configurados para o diagnóstico de motor saudável/motor com defeito.

Tabela 1: Resultados experimentais - Classificação de falhas de rolamentos

Atributos	k -NN	PMC
Instâncias corretamente classificadas (%)	98,78	99,44
Instâncias incorretamente classificadas (%)	1,22	0,56
Estatística Kappa	0,95	0,97
Erro absoluto médio	0,01	0,01
Erro quadrático	0,11	0,06
Erro absoluto relativo (%)	5,16	2,46
Erro quadrático relativo (%)	37,75	20,09

A partir da Tabela 1 é possível observar que o algoritmo PMC apresenta melhor precisão global de classificação, atingindo 99,44% de precisão global, seguido pelo classificador k -NN, com 98,78%. Os classificadores obtiveram alto índice Kappa, indicando perfeita concordância dos resultados.

Tabela 2: Matriz de confusão - Classificação de falhas de rolamentos

Classes	Classes previstas			
	k -NN		PMC	
Normal	482	14	481	15
Falha	29	2994	5	3019

A matriz de confusão da Tabela 2, mostra que o algoritmo PMC possui precisão de 97% para o diagnóstico de motor saudável e 99,8% para identificação de motor com defeito de rolamento. O algoritmo k -NN apresenta precisão de 97,2% para motor saudável e 99% de precisão para indicação do motor com defeito.

No caso da classificação considerando a evolução de uma falha de rolamento ao longo do tempo, foram consideradas 4 situações distintas de desgaste, a saber: desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. As Tabelas 3 e 4 apresentam os resultados obtidos considerando a da evolução de uma falha de rolamento.

Os resultados apresentados na Tabela 3 mostram que o algoritmo k -NN apresenta melhor desempenho global de classificação, atingindo 44,14% de precisão global, seguido pelo classificador PMC com 41,10% de precisão global. Para

Tabela 3: Resultados experimentais - Multiclassificação de falhas de rolamentos

Atributos	k -NN	PMC
Instâncias corretamente classificadas (%)	44,14	41,10
Instâncias incorretamente classificadas (%)	55,85	58,90
Estatística Kappa	0,30	0,26
Erro absoluto médio	0,22	0,24
Erro quadrático	0,47	0,38
Erro absoluto relativo (%)	70,24	76,84
Erro quadrático relativo (%)	118,96	96,42

estes testes, todos os classificadores obtiveram baixos índices de concordância. Este fato confirma que os classificadores não conseguiram diferenciar com sucesso as diversas classes estabelecidas na metodologia proposta para determinação da evolução do nível de severidade da falha.

Tabela 4: Matriz de confusão - Multiclassificação de falhas de rolamentos

Classes	Classes previstas				
	k -NN				
Normal	481	1	2	7	5
Inicial	5	230	135	160	220
Médio	4	127	278	172	169
Avançado	9	150	145	296	162
Severo	7	185	140	161	269

Classes	Classes previstas				
	PMC				
Normal	481	2	5	6	2
Inicial	8	205	178	210	149
Médio	7	109	317	159	158
Avançado	6	164	203	250	159
Severo	6	157	209	196	194

A matriz de confusão da Tabela 4 mostra que o algoritmo k -NN manteve precisão de 97% para o diagnóstico do motor saudável. Este resultado é similar ao obtido na classificação de motor com defeito / motor saudável. No entanto, para a multiclassificação de severidade das falhas os índices de precisão obtidos foram respectivamente 27,3%, 42,3%, 32,8% e 25,8% para classificação de rolamento com nível de desgaste inicial, desgaste médio, desgaste avançado e desgaste severo. Nos testes efetuados com o algoritmo PMC também foi mantido o mesmo nível de precisão para indicação de motor saudável; a saber: 97%. Em relação as classificações para evolução do desgaste foram obtidos índices de precisão de 30,7%, 37,1%, 38,8% e 35,3%, respectivamente.

5 Conclusões

Neste trabalho foi investigado a evolução da falha de rolamentos em MIT alimentado por diferentes modelos de inversores de frequência. O método proposto não é influenciado por variações na dinâmica da carga ou mesmo por variações de velocidade, confirmando assim sua aplicabilidade sob diversas condições de trabalho.

A identificação de falhas permite aumentar a confiabilidade das máquinas além de reduzir custos de manutenção. Também foi avaliado o desempenho de duas técnicas distintas de classificação.

Ambos os métodos PMC e k -NN são capazes de diagnosticar de forma rápida e precisa defeitos rolamentos em MIT acionados por diferentes modelos de inversores de frequência.

Os resultados experimentais confirmam a eficácia desta abordagem para a correta identificação de motor saudável e falhas de rolamentos. A avaliação do nível de severidade trata-se de uma ferramenta complementar para auxiliar no processo de tomada de decisão.

Agradecimentos

Os autores agradecem as contribuições do CNPq (Processo #552269/2011-5), FAPESP (Processo #2011/17610-0), “Ministerio de Economía y Competitividad” (MINECO) do governo da Espanha e o programa FEDER “Proyectos I+D del Subprograma de Generación de Conocimiento, Programa Estatal de Fomento de la Investigación Científica y Técnica de Excelencia” (Processo # DPI2014-52842-P) e a Universidade Tecnológica Federal do Paraná - Campus Cornélio Procopio, pelo apoio financeiro para o desenvolvimento desta pesquisa.

Referências

- Abu-Rub, H., Ahmed, S., Iqbal, A., Rahimian, M. and Toliyat, H. (2010). Incipient bearing fault diagnostics for inverter fed induction motor drive using anfis, *XIX International Conference on Electrical Machines (ICEM)*, pp. 1–5.
- Araújo, R. d. S. (2011). *Desgaste Prematuro e Falhas Recorrentes em Rolamentos de Motores de Indução Alimentados por Inversores: Análise e Proposta de Solução*, Doutorado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais.
- 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.
- 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.
- Duda, R. O., Hart, P. E. and Stork, D. G. (2001). *Pattern Classification*, 2 edn, J. Willey and Sons, Inc, New York.
- Ghorbanian, V. and Faiz, J. (2015). A survey on time and frequency characteristics of induction motors with broken rotor bars in line-start and inverter-fed modes, *Mechanical Systems and Signal Processing* **54 - 55**(0): 427 – 456.
- Godoy, W., da Silva, I., Goedtel, A., Palacios, R. and Gongora, W. (2014). Neural approach for bearing fault classification in induction motors by using motor current and voltage, *2014 International Joint Conference on Neural Networks (IJCNN)*, pp. 2087–2092.
- Han, J., Kamber, M. and Pei, J. (2011). *Data Mining: Concepts and Techniques*, 3 edn, Elsevier: Morgan Kaufmann, Amsterdam.
- Jia, F., Lei, Y., Lin, J., Zhou, X. and Lu, N. (2016). Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, *Mechanical Systems and Signal Processing* **72 - 73**: 303 – 315.
- Muetze, A. and Binder, A. (2007). Practical rules for assessment of inverter-induced bearing currents in inverter-fed ac motors up to 500 kw, *IEEE Transactions on Industrial Electronics* **54**(3): 1614–1622.
- Onel, I., Aycicek, E. and Senoll, I. (2009). An experimental study, about detection of bearing defects in inverter fed small induction motors by concordia transform, *Journal of Intelligent Manufacturing* **20**(2): 243–247.
- Riera-Guasp, M., Antonino-Daviu, J. A. and Capolino, G. A. (2015). Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State of the art, *IEEE Transactions on Industrial Electronics* **62**(3): 1746–1759.
- S., M. G. and Hegde, V. (2016). Application of mems accelerometer for detection and diagnosis of multiple faults in the roller element bearings of three phase induction motor, *IEEE Sensors Journal* **16**(1): 145–152.
- Seera, M., Lim, C., Ishak, D. and Singh, H. (2012). Fault detection and diagnosis of induction motors using motor current signature analysis and a hybrid fmm-cart model, *IEEE Transactions on Neural Networks and Learning Systems* **23**(1): 97–108.
- Seera, M., Lim, C. P., Nahavandi, S. and Loo, C. K. (2014). Condition monitoring of induction motors: A review and an application of an ensemble of hybrid intelligent models, *Expert Systems with Applications* **41**(10): 4891 – 4903.
- Yilmaz, M. and Ayaz, E. (2009). Adaptive neuro-fuzzy inference system for bearing fault detection in induction motors using temperature, current, vibration data, *IEEE EUROCON 2009*, pp. 1140–1145.