CLASSIFICADOR NÃO SUPERVISIONADO BASEADO EM CURVAS PRINCIPAIS PARA DETECÇÃO DE FALHAS EM MOTOR DE INDUÇÃO

FERNANDO E. M. BORGES, DIOGO A. RIBEIRO, OTÁVIO F. MOTA, DANTON D. FERREIRA, BELISÁRIO N. HUALLPA

Departamento de Engenharia, Universidade Federal de Lavras Caixa Postal 6969, 12345-678, Lavras, MG, BRASIL

E-mails: fernandoelias-mb@outlook.com, diogoaranhavga@gmail.com, otaviofidelis@hotmail.com, danton@deg.ufla.br, belisario.nina@deg.ufla.br

Abstract—Electric motors are highly versatile equipment, possessing an immense range of industrial applications. Therefore, they are extremely important in any industrial plant and their maintenance is crucial for their quality operation in production, safety to employees and without environmental damages. In this paper a method for fault detection is proposed by means of vibration analysis, based on structural health monitoring. Vibration signals of a three-phase induction motor were collected using a 3-axis accelerometer sensor controlled by an Arduino microcontroller. After the collection, the extraction of features through the 2nd, 3rd and 4th order cumulants with lag zero was performed. Finally, a classifier is designed using principal curves. Principal curves are a non-linear generalization of Principal Component Analysis and have the advantage of presenting good data representation capability in one dimension. A one-class learning method based on Principal Curves is proposed to generate a decision border where the data within it represents the data of non-failed motor and out of it, the data referring to the failed motor. The method presented low computational cost and high detection rates, reaching up to 100% using real data from an induction motor.

Keywords-Vibration Analysis, Structural Health Monitoring, Principal Curves.

Resumo—Motores elétricos são equipamentos de alta versatilidade, possuindo uma gama imensa de aplicações nas indústrias. Portanto, são extremamente importantes em qualquer planta industrial e sua manutenção é crucial para a qualidade na produção, segurança aos colaboradores e sem danos ambientais. Neste artigo é proposto um método para detecção de falhas por meio de análise de vibrações, baseado no monitoramento da integridade estrutural. Os sinais de vibração de um motor de indução trifásico foram coletados utilizando um acelerômetro de 3 eixos controlado por um microcontrolador Arduino. Após as coletas foi realizada a extração de parâmetros por meio dos cumulantes de 2ª, 3ª e 4ª ordens com atraso zero. Por fim, projetado um classificador utilizando Curvas Principais. Curvas Principais são uma generalização não-linear da Análise de Componentes Principais e possui vantagem em apresentar boa capacidade de representação dos dados em uma dimensão. O método de *oneclass learning* baseado em Curvas Principais é proposto para gerar uma fronteira de decisão onde os dados dentro desta são referentes ao motor sem falha e os dados fora, referentes ao motor com falha. O método apresentou baixo custo computacional e altas taxas de detecção, chegando até 100% utilizando dados reais de um motor de indução.

Palavras-chave-Análise de Vibrações, Monitoramento de Integridade Estrutural, Curvas Principais.

1 Introdução

Atualmente, com os avanços tecnológicos, o setor industrial vem se modernizando cada vez mais, fazendo maior uso de automação, com equipamentos interligados, a internet das coisas (IoT), etc. Tal avanço é tido como uma nova era industrial, também conhecida como indústria 4.0 (Thoben *et al*, 2017).

Devido a este novo panorama as indústrias estão se reestruturando com a aquisição de máquinas e equipamentos de alto valor agregado com alta fiabilidade e produtividade, as quais necessitam de um programa elaborado de manutenção voltado à predição de falhas, garantindo maior produtividade com segurança, qualidade e sem prejuízos ambientais. A manutenção vem se desenvolvendo por meio do avanço de técnicas de manutenção preditiva (Liao e Wang, 2013). Tal metodologia se baseia na análise das condições de determinados componentes de máquinas com o objetivo de otimizar a vida útil dos mesmos.

Neste contexto, uma das práticas adotadas é o monitoramento da integridade estrutural (ou SHM – *Structural Health Monitoring*). Vários autores fizeram uso desta abordagem, como publicado por (Farrar e Worden, 2012) em que os autores utilizaram metodologias do SHM acrescidas de técnicas avançadas de processamento de sinais e reconhecimento de padrões. No trabalho publicado por (Avendano-Valencia e Fassois, 2014), os autores fizeram o uso do SHM para detecção de falhas em uma turbina eólica simulada utilizando séries temporais, em que boas taxas de acertos foram obtidas. Já os autores (Mustapha et al, 2015) aplicaram a metodologia do SHM por meio de estimações de modelos autorregressivos ou autorregressivos com entradas exógenas (AR ou ARX, respectivamente) para detecção de falhas em uma ponte com resultados promissores. (Hernandez-Garcia e Masri, 2014) utilizaram o SHM para fins de detecção de falhas em sensores, por meio de técnicas de processamento estatístico de sinais. Foram utilizados como técnicas a análise de componentes (PCA), análise de componentes principais independentes (ICA) e análise de componentes independentes modificada (MICA) para detecção de alguns tipos de falhas em sensores com resultados interessantes. (Barbosa et al, 2016) propuseram uma metodologia de detecção de falhas em uma viga engastada utilizando estatísticas de ordem superior (EOS) (Mendel, 1991) como parâmetros de detecção por meio de cumulantes de segunda terceira e quartas ordens. Os autores identificaram que o atraso

temporal (*lag*) zero dos cumulantes apresentaram melhor taxa de detecção utilizando o discriminante linear de Fisher (FDR). Os autores utilizaram como classificador uma rede neural *multi-layer perceptron* (MLP) em que boas taxas de detecção foram alcançadas.

Para manutenção preditiva em motores elétricos, há na literatura estudos de casos de trabalhos baseados em análise de corrente com base em respostas em frequência. Como em (Culbert e Letal, 2017) em que autores propuseram uma abordagem de detecção de falhas no rotor em um motor trifásico, identificando falhas por quebra no rotor ou desbalanceamento do vão entre o estator e o rotor. Os obtiveram resultados satisfatórios autores conseguindo identificar as frequências de falha em ambos os casos. (Park et al, 2017) realizaram um estudo em uma bomba centrífuga, analisando além das frequências de falha da mesma, a influência da frequência de rotação das lâminas na identificação das falhas, acarretando em resultados falsos. Os autores constataram a influência da frequência de rotação das lâminas e propuseram abordagens de discriminação entre as frequências das lâminas e de falhas, a fim de evitar falsos positivos e negativos.

No presente artigo foi realizado um estudo de SHM mediante a realização de ensaio de vibração, realizado por meio de uma coleta de dados (sinais de vibração) em um motor de indução trifásico, com a utilização de um acelerômetro de 3 eixos. Buscou-se detectar a falha por desgaste no rolamento do motor. Tal tipo de falha é a mais recorrente em motores elétricos, correspondendo por 44% das ocorrências de falhas (Gongora *et al*, 2016). Portanto sendo de suma importância a detecção de tal falha em estágio inicia, evitando sua propagação e, consequentemente, prejuízos na produção.

Os parâmetros foram os mesmos utilizados por (Barbosa *et al*, 2016), os cumulantes de segunda, terceira e quarta ordens no *lag* zero. Como classificador foram utilizadas uma abordagem de Curvas Principais, método desenvolvido inicialmente por (Hastie e Stuetzle, 1989). A partir deste método, outros algoritmos alternativos para extrair Curvas Principais de maneira mais robusta e eficiente foram desenvolvidos. Dentre estes segue o algoritmo ksegmentos não suave proposto por (Verbeek, Vlassis e Krose, 2001) que foi o algoritmo utilizado neste trabalho. Este gera as Curvas Principais por meio de conexões entre segmentos de reta de maneira incremental e possui convergência prática garantida.

As Curvas Principais vêm sendo aplicadas em problemas de classificação com bastante sucesso em seus resultados. (Fernandes, 2005) propôs uma metodologia de classificação de navios usando classificadores baseados em Curvas Principais. (Faier, 2006) utilizou Curvas Principais para identificação de descargas parciais em equipamentos de potência obtendo resultados satisfatórios.

Outros exemplos de aplicações de Curvas Principais podem ser vistos em (Ferreira *et al*, 2013) (Ferreira *et al*, 2014) (Ferreira *et al*, 2015) em que os autores utilizaram as Curvas Principais na detecção e no monitoramento de distúrbios elétricos, obtendo além de altas taxas de detecção, um classificador com baixo custo computacional, gerando resultados promissores. Além do seu uso como classificador, as Curvas Principais podem ser utilizadas como método de clusterização, como proposto em (Moraes e Ferreira, 2016).

Por meio da extração das Curvas Principais é proposto um classificador para detecção de falhas em motores elétricos. O classificador é não supervisionado ou *one class*, em que apenas uma das classes do problema é utilizada para o projeto do classificador.

2 Método Proposto

O método proposto consiste em 3 etapas: a aquisição de sinais, em que os sinais de vibração do motor são coletados por meio do acelerômetro; a extração de parâmetros, em que são extraídos os cumultantes de segunda, terceira e quarta ordens no *lag* zero; e, por fim, o projeto do classificador baseado em Curvas Principais e no conceito *one*-*class learning*. O método proposto pode ser ilustrado de maneira simplificada na Figura 1.



Figura 1. Fluxograma do método proposto

2.1 Aquisição de sinais

A aquisição de sinais foi realizada utilizando para testes um motor de indução da marca KOHLBACH® de 2CV, tensão de alimentação 380V e rotação nominal de 3.480rpm. A falha a ser detectada foi induzida no rolamento traseiro de modelo NSK 6204. Foram utilizados dois rolamentos, um sem falha e outro com falha. A falha analisada no rolamento utilizado no experimento foi causada por desgaste acumulado devido à falta de lubrificação. Ou seja, uma falha que indica que o rolamento necessita ser lubrificado ou substituído por um novo.

Os sinais foram coletados por um acelerômetro de 3 eixos modelo MMA 7361, com dimensões de 27,9 mm por 18,6 mm; banda de frequência média nos eixos X e Y de 400 Hz; banda de frequência média no eixo Z de 300 Hz; massa de 2,5g.

Para coletar os sinais do sensor foi utilizado um microcontrolador Arduino® modelo MEGA 2560. Os dados foram armazenados em um arquivo de planilhas para as próximas etapas do método utilizando o ambiente MatLab®.

Durante a aquisição foi realizada utilizando uma frequência de amostragem de 200Hz. Cada coleta foi feita por 2 minutos, gerando um total de 24.000 amostras por coleta. Primeiramente foram realizadas 20 coletas com o motor com o rolamento em bom estado, após as coletas o motor foi desmontado, montado com o rolamento com falha e realizados novos 20 ensaios. As coletas foram realizadas com o sensor fixado na tampa traseira do motor e nos eixos $x \in y$ do acelerômetro O sensor utilizado, os rolamentos com e sem falha e a montagem do experimento em bancada são ilustrados nas Figuras 2, 3 e 4, respectivamente. O posicionamento do sensor na tampa traseira do motor indicando o sentido adotado aos eixos medidos do acelerômetro é mostrado na Figura 5.



Figura 2. Sensor utilizado no experimento





Figura 4. Montagem do experimento em bancada



Figura 5. Indicação do posicionamento do sensor no motor e indicação dos eixos medidos pelo acelerômetro.

2.2 Extração de Parâmetros

Nesta etapa serão extraídos os parâmetros relevantes à classificação. Serão extraídas EOS por meio dos cumulantes de segunda, terceira e quarta ordens no *lag* zero, estes identificados por (Barbosa *et al*, 2016) como os mais relevantes para detecção de falhas.

As EOS apresentam elevada robustez ao ruído (Mendel, 1991), algo de interesse neste experimento, dado que os sinais de vibração podem vir acrescidos de ruídos provenientes do processo de medição.

Para este trabalho foram utilizadas as aproximações estocásticas para sinais de comprimento finito N, dos cumulantes de segunda, terceira e quarta ordens, descritas, respectivamente, nas equações (1), (2) e (3).

$$\hat{C}_{2,x}[0] := \frac{2}{N} \sum_{n=0}^{N} x[n] x[mod[n, N]]$$
(1)

$$\hat{\mathcal{L}}_{3,x}[0] := \frac{2}{N} \sum_{n=0}^{N} x[n] x^2[mod[n,N]]$$
(2)

$$\hat{\mathcal{C}}_{4,x}[0] := \frac{2}{N} \sum_{n=0}^{N} x[n] x^3 [mod[n,N]]$$
(3)

$$-\frac{2}{N^2}\sum_{n=0}^{N}x[n]x[mod[n,N]]\sum_{n=0}^{N}x^2[n]$$

Onde x é o vetor aleatório referente ao sinal de entrada e mod[n, N] é o resto da divisão da posição ndo vetor do sinal de entrada em relação ao comprimento total do vetor N.

2.3 Projeto do Classificador

Para o projeto do classificador foram utilizadas as Curvas Principais inseridas em uma metodologia de *one-class learning*. O uso das Curvas Principais se dá pela complexidade de representação e compactação dos dados que são utilizados para o projeto do classificador.

Além da representação complexa dos dados, o não conhecimento preciso da falha e sua gravidade, pode inviabilizar o uso de classificadores de modelagem mais simples e de separação linear, pois falhas muito pequenas podem causar falso negativo. Para evitar tal erro de classificação se torna mais viável o uso de uma metodologia de classificação não supervisionada.

O método gera uma fronteira compacta de classificação, de maneira a evitar falsos positivos tanto na fase de treino, quanto na fase de teste.

2.3.1 Curvas Principais

O método de Curvas Principais foi primeiramente desenvolvido por (Hastie e Stuetzle, 1989) como um método de extração de parâmetros e uma forma compacta de representação de dados. possui como características não serem paramétricas e a sua forma é sugerida pelos dados em que serão usadas para projetá-la.

Alguns outros algoritmos foram surgindo para fins de melhoramento do método anteriormente descrito, como o método k-segmentos não suave proposto por (Verbeek, Vlassis e Krose, 2001) este possui maior robustez, menor susceptividade à mínimos locais e convergência prática garantida, o que o fez se destacar dos outros métodos de extração de Curvas Principais. O algoritmo do método ksegmentos gera as Curvas Principais de maneira incremental, sendo o primeiro segmento formado pela componente principal e os demais sendo formados com base nas regiões de Voronoi.

O algoritmo é composto por 3 passos: o passo 0 consiste em inserir o primeiro segmento utilizando um agrupamento com todo o conjunto de dados para o projeto da curva. O segmento é inserido na direção da primeira componente principal e com tamanho 3/2 do desvio padrão dos dados ao longo do segmento. O passo 1 consiste na inserção de um próximo segmento utilizando um novo conjunto de dados por meio do algoritmo k-means. Esse novo agrupamento é baseado nas regiões de Voronoi, estas que são compostas por eventos mais próximos do centro da região que dos segmentos que compõem a curva. Recalcula-se o primeiro segmento, devido à alteração do seu agrupamento. Os segmentos são ligados por uma linha reta. Para os demais segmentos, o passo é o mesmo. Por fim, o passo 2 consiste na análise da convergência da curva, esta feita de duas formas: a primeira consiste em verificar se o número de segmentos (K) atingiu o número máximo de segmentos estabelecido pelo usuário (K_{max}) ou se o maior agrupamento possui menos de três eventos. Caso nenhuma das duas condições sejam atendidas, o algoritmo retorna ao passo 1.

A Figura 6 apresenta um fluxograma do algoritmo k-segmentos para a obtenção das Curvas Principais.



Figura 6. Fluxograma do método k-segmentos para obtenção de Curvas Principais

2.3.2 Curvas Principais como classificador

Para realizar a detecção de falhas, foram utilizadas as Curvas Principais no contexto de *one-class learning* (Schölkopf *et al*, 2001), gerando assim, um classificador não supervisionado. Tal metodologia é usada quando apenas uma das classes é conhecida e a outra é determinada como *outlier*. Neste trabalho, a classe conhecida é a classe referida como o motor sem falha e os dados classificados como *outliers* são referentes ao motor com falha.

Primeiramente, foi gerada a curva principal utilizando os dados de treino do motor sem falha. Após a geração da curva, foi realizado um mapeamento das distâncias de cada evento de treino até a curva. O quadrado da distância Euclidiana foi utilizado como métrica. A partir deste mapeamento, foram calculadas a distância máxima e o desvio padrão da média das distâncias.

Para classificar os dados foi gerada uma fronteira de decisão para separar os dados do motor sem falha dos dados do motor com falha. Tal fronteira foi gerada com base na distância máxima de um evento de treino para curva principal acrescida de uma tolerância. Tal tolerância foi o desvio padrão da média das distâncias de cada evento até a curva obtida. A partir deste limiar (distância máxima mais desvio padrão) a fronteira de decisão foi gerada de maneira a abranger os dados de treino utilizados para a curva.

Para a classificação dos dados foi utilizada a seguinte regra: os dados cuja distância fosse menor que o limiar, serão classificados como dados referentes ao motor sem falha, caso contrário, serão classificados como dados referentes ao motor com falha (*outliers*). De maneira mais simplificada,

atribuindo-se resultado 0 para o dado sem falha e 1 para o dado com falha, pode-se escrever a regra como na Equação (4).

$$\begin{cases} 0, se \ d \le L \\ 1, se \ d > L \end{cases}$$

$$\tag{4}$$

Em que d é a distância de um dado evento à curva principal e L é o limiar (distância máxima mais o desvio padrão), definido na etapa de projeto.

3 Resultados e Discussão

Durante a coleta dos sinais via acelerômetro, os testes foram feitos nos dois eixos conforme ilustra a Figura 5, entretanto, o eixo x apresentou melhor capacidade de discriminação entre classes, sendo, portanto, o escolhido para ser utilizado nas análises.

Após a coleta dos sinais de vibração do motor com e sem falha, os dados foram divididos em eventos, cada evento contendo 1.500 amostras, apresentando um total de 320 eventos para os 20 ensaios realizados. As Figuras 7 e 8 apresentam, respectivamente, os sinais de aceleração em função do número de amostras, de um evento para o motor sem falha e um para o motor com falha. Estes eventos foram escolhidos aleatoriamente no banco de dados.



Figura 7. Sinal de aceleração para o motor sem falha





Após a aquisição dos sinais de vibração, foram extraídos os cumulantes de segunda, terceira e quarta ordens com atraso nulo, tal atraso utilizado de acordo com os resultados reportados por (Barbosa *et al*, 2016). Estes foram agrupados em pares (cumulantes de 2^a e 3^a ordens, de 2^a e 4^a ordens e 3^a e 4^a ordens) com o propósito de investigar qual é a melhor combinação destes. Este agrupamento foi feito uma análise de cada par e observar os resultados obtidos para escolha do par com os melhores resultados. Analisando a distribuição dos dados no espaço de características (EOS), foi constatado que o par de cumulantes de 2^a e 4^a ordens gerou os melhores resultados. Portanto, estes foram utilizados para os experimentos finais.

Realizada a extração dos parâmetros, foi projetado o classificador. Para o projeto deste foram divididos os dados em conjuntos de dados de treino e de teste. Para os dados do motor sem falha, o tamanho do conjunto de treino N_t foi variado de 50 à 250 eventos, em intervalos de 50. Para os dados do motor com falha, todos os dados foram utilizados para teste, dado que o método proposto segue a metodologia de *one-class learning*.

Durante o projeto do classificador foram geradas as Curvas Principais pelo método k-segmentos não suave apenas para os cumulantes referentes ao motor sem falha. Em seguida, uma fronteira de decisão foi construída a partir da curva principal obtida.

Durante a geração das Curvas Principais, foram feitos vários testes empíricos e foi encontrado um valor de segmentos k = 20 de maneira que se obtivesse uma boa representação dos dados. A Figura 9 mostra uma representação da curva principal para um conjunto de treino com 200 eventos. Observe que a curva principal atravessa os dados no espaço de parâmetros gerando uma boa representação dos mesmos.



Figura 9. Dados gerados para curva e curva principal obtida para conjunto de dados de treino $N_t = 200$

Após a geração da curva principal o limiar de decisão foi obtido considerando-se a máxima distância dos eventos de treino à curva mais o desvio padrão em relação à média das distâncias dos eventos à curva.

Na Figura 10 são mostrados os dados de treino e teste para o motor sem falha, os dados de teste para o

motor com falha, além da fronteira de decisão do classificador. Observe que a fronteira de decisão envolve todos os dados de treino e teste referentes ao motor com falha.



Figura 10. Classificador gerado pelas Curvas Principais e *one*class learning contendo os dados de treino e teste do motor sem falha e os dados de teste para o motor com falha e fronteira de decisão para $N_t = 200$

Após a geração dos gráficos do classificador, foram gerados os dados estatísticos para análise quantitativa do acerto do classificador nas fases de treino e teste do mesmo. Para isto, o algoritmo foi executado 100 vezes variando-se aleatoriamente o conjunto de treino e teste para a classe do motor sem falha. O número de eventos de treino N_t foi variado de 50 a 250 e a métrica de desempenho foi o percentual médio de acertos do classificador μ com uma incerteza de seu desvio padrão σ . Os resultados obtidos são mostrados na Tabela 1. Taxas de acertos superiores a 97% foram obtidas.

| N _t | Treino (classe sem falha) | Teste (classe sem falha) | Teste (classe com falha) |
|----------------|---------------------------|--------------------------|-----------------------------|
| 50 | $100,00 \pm 0,00$ | $97,\!17\pm2,\!14$ | $100,00 \pm 0,00$ |
| 100 | $100,00 \pm 0,00$ | $97,\!32\pm1,\!94$ | $100,00 \pm 0,00$ |
| 150 | $100,00 \pm 0,00$ | $98,11 \pm 1,50$ | $100,00 \pm 0,00$ |
| 200 | $100,00 \pm 0,00$ | $98,75 \pm 1,45$ | $100,00 \pm 0,00$ |
| 250 | $100,00 \pm 0,00$ | $99,14 \pm 1,35$ | $100,00 \pm 0,00$ |

Tabela 1. Taxas de acerto % ($\mu \pm \sigma$)

Um ponto a se destacar analisando o espaço de parâmetros gerado pelo classificador (Figura 10) é a separação linear entre as classes. Todavia, devido ao não conhecimento da falha e sua dimensão, o uso de um classificador não supervisionado foi necessário.

Na Tabela 1, as taxas de 100% de acerto na fase de treino, devem-se à escolha do limiar de decisão, que foi capaz de envolver todos os dados de treino do motor sem falha.

Observa-se uma pequena sensibilidade do classificador ao tamanho do conjunto dos dados de treino, o que já era esperado, já que a curva principal é construída a partir deste. Com o aumento de 5 vezes no tamanho do conjunto de treino, houve um aumento de 2% na média dos acertos e redução no

desvio padrão de menos de 1%. Logo, pode-se obter um classificador com boas taxas de acerto com um conjunto de treino relativamente pequeno sem grandes perdas em seu desempenho.

4 Conclusão

Após os procedimentos de implementação do método, testes, aquisição dos resultados e interpretação dos mesmos, alguns pontos importantes merecem destaque.

Primeiramente, o classificador apresentou uma boa detecção das falhas, pela representatividade dos sinais de vibração pelas EOS e destas últimas pela curva principal. Além disso, obtiveram-se bons resultados nos testes para a própria classe sem falha, reduzindo, assim, as taxas de falsos positivos.

Após a coleta dos sinais, o método de extração de parâmetros e projeto do classificador é toda feita de forma *off-line* e de baixo tempo de processamento, tempo em torno de 7 minutos.

O sistema de aquisição de sinais implementado em bancada possui baixo custo e uso de *hardware open-source* (placa Arduino®), o que é interessante devido à gama de implementações já disponíveis.

Por fim, o método proposto atendeu de maneira satisfatória ao objetivo de detecção de falhas utilizando dados reais de um motor de indução. Para projetos futuros, visa-se uma análise na questão do grau de gravidade da falha com o objetivo de classificar a falha de acordo com sua gravidade. Podendo, assim, auxiliar em futuras tomadas de decisões para trocas de peças, otimizando a vida útil dos componentes de motores elétricos. Tais tomadas de decisão poderão garantir maior produtividade da planta, com maior qualidade dos produtos e segurança aos operadores das indústrias.

Agradecimentos

Agradecimentos à pró-reitoria de pesquisa da Universidade Federal de Lavras (PRP – UFLA) CAPES, FAPEMIG e CNPq pelo suporte financeiro e à Bobinadora Lavrense pelo empréstimo do motor usado no experimento.

Referências Bibliográficas

- Avendano-Valencia, D.; Fassois, S. D. Robust fault detection based on multiple functional series TAR models for structures with time-dependent dynamics. In: EWSHM-7th European Workshop on Structural Health Monitoring. 2014.
- Barbosa, T. S. et al. Fault Detection and Classification in Cantilever Beams Through Vibration Signal Analysis and Higher-Order Statistics. Journal of Control, Automation and Electrical Systems, v. 27, n. 5, p. 535-541, 2016.
- Culbert, I.; Letal, J. Signature Analysis for Online Motor Diagnostics: Early Detection of Rotating

Machine Problems Prior to Failure. IEEE Industry Applications Magazine, v. 23, n. 4, p. 76-81, 2017.

- Faier, J. M., Curvas Principais Aplicadas na Identificação de Descargas Parciais em Equipamentos de Potência, COPPE/UFRJ, Rio de Janeiro, RJ, 2006.
- Farrar, C. R.; Worden, K. Structural health monitoring: a machine learning perspective. John Wiley & Sons, 2012.
- Fernandes, H. L., Classificação de Navios Baseado em Curvas Principais, Tesede Mestrado, Programa de Engenharia Elétrica, COPPE/UFRJ, Rio de Janeiro, RJ, 2005.
- Ferreira, D. D.; De Seixas, J. M.; Cerqueira, A. S.; Duque, C. A.; Bollen, M. H. J.; Ribeiro, P. F. A new power quality deviation index based on principal curves. Electric Power Systems Research, v. 125, pp. 8-14, 2015.
- Ferreira, D. D.; Seixas J. M.; Cerqueira, A. S.; Duque, C. A. Exploiting principal curves for power quality monitoring. Electric Power Systems Research, v. 100, pp. 1-6, 2013.
- Ferreira, D. D.; Seixas J. M.; Duque, C. A.; Cerqueira, A. S.; Ribeiro, P. F. A direct approach for disturbance detection based on Principal Curves. In: 16th International Conference on Harmonics and Quality of Power (ICHQP), 2014, Bucharest, Romania. Anais do 16th International Conference on Harmonics and Quality of Power (ICHQP), 2014. pp. 747-751.
- Gongora, W. S.; Goedtel, A.; da Silva, S. A. O.; Graciola, C. L.. Neural Approach to Fault Detection in Three-phase Induction Motors. IEEE Latin America Transactions, v. 14, n. 3, p. 1279-1288, 2016.
- Hastie, T. J., Stuetzle, W., "Principal Curves", Journal of the American Statistical Association, v. 84, n. 406, pp. 502-516, 1989.
- Hernandez-Garcia, M. R.; Masri, S. F. Application of statistical monitoring using latent-variable techniques for detection of faults in sensor networks. Journal of Intelligent Material Systems and Structures, v. 25, n. 2, p. 121-136, 2014.
- Liao, W; Wang, Y. Data-driven Machinery Prognostics Approach using in a Predictive Maintenance Model. JCP, v. 8, n. 1, p. 225-231, 2013.
- Mendel, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications. Proceedings of the IEEE, v. 79, n. 3, p. 278-305, 1991.
- Moraes, E. C. C.; Ferreira, D. D. A principal curvebased method for data clustering. In: 2016 International Joint Conference on Neural Networks (IJCNN), 2016, Vancouver. 2016 International Joint Conference on Neural Networks (IJCNN). pp. 3966-3971.
- Mustapha, S. et al. Pattern recognition based on time series analysis using vibration data for structural

health monitoring in civil structures. Electronic Journal of Structural Engineering, 2015.

- Park, Y.; Jeong, M.; Lee, S. B.; Antonino-Daviu, J. A.; Teska, M. Influence of Blade Pass Frequency Vibrations on MCSA-Based Rotor Fault Detection of Induction Motors. IEEE Transactions on Industry Applications, v. 53, n. 3, p. 2049-2058, 2017.
- Schölkopf, B. et al. Estimating the support of a highdimensional distribution. Neural computation, v. 13, n. 7, p. 1443-1471, 2001.
- Thoben, K; Wiesner, S; Wuest, T. "Industrie 4.0" and Smart Manufacturing–A Review of Research Issues and Application Examples. Int. J. of Automation Technology Vol, v. 11, n. 1, 2017.
- Verbeek, J. J., Vlassis, N., Krose, B., "A soft ksegments algorithm for principal curves", Proceedings of International Conference on Artificial Neural Networks, pp. 450-456, 2001.