DOI: 10.48011/asba.v2i1.1389

Uso de Curvas Principais na Classificação de Falhas em Motor de Indução Trifásico

Letycia M. Borges. * **Fernando E. M. Borges.** ** **Diogo A. Ribeiro.** *** **Andrey W. M. Pinto.** **** **Danton D. Ferreira.** †

* *Departamento de Engenharia, Universidade federal de Lavras, MG, (e-mail: letycia.borges@estudante.ufla.br)*
** *Departamento de Automática, Universidade Federal de Lavras, MG (e-mail: fborges@estudante.ufla.br)*
*** *Departamento de Automática, Universidade Federal de Lavras, MG (e-mail: diogoaranhavga@gmail.com)*
**** *Departamento de Automática, Universidade Federal de Lavras, MG (e-mail: andreymarques96@gmail.com)*
† *Departamento de Automática, Universidade Federal de Lavras, MG (e-mail: danton@ufla.br)*

Abstract: : In this paper, a method predictive maintenance of electric motors is proposed, through the fault classification in the motor bearings. The method is based on four steps: signal acquisition, feature extraction, classifier design and analysis of the results. The signal acquisition was made through a 3-axis accelerometer coupled on a 3-phase induction motor. The vibration signals were collected using an Arduino board. The feature extraction was made using Higher-Order Statistics (HOS) though second and fourth orders with lag zero cumulants. Principal Curves were used te design the classifier through k-segments algorithm. For the tests, three conditions of front bearing of the motor were evaluated: bearing without faults, bearing with fault in the outer race and bearing with fault in the two races. Classification results in test phase presented hit rates above 95%.

Resumo: Neste artigo é proposto um método de manutenção preditiva de motores elétricos, por meio da classificação de falhas nos rolamentos do motor. O método consiste em quatro etapas: aquisição de sinais, extração de características, projeto do classificador e análise dos resultados. A aquisição de sinais foi feita por meio de um acelerômetro de 3 eixos acoplado a um motor de indução trifásico. Os sinais de vibração foram coletados utilizando uma placa Arduino. A extração de parâmetros foi realizada utilizando estatísticas de ordem superior (EOS) por meio dos cumulantes de segunda e quarta ordens com atraso zero. Para o projeto do classificador foram utilizadas Curvas Principais via algoritmo k-segmentos. Para testes, foram avaliadas três condições do rolamento dianteiro do motor: rolamento sem falhas, rolamento com falha na pista externa e rolamento com falha nas duas pistas. Resultados de classificação em fase de teste apresentaram taxas de acerto acima de 95%.

Keywords: Induction Motor; Principal Curves; Vibration Analysis; Fault Classification; Higher-Order Statistics.

Palavras-chaves: Análise de Vibrações; Curvas Principais; Classificação de Falhas; Estatísticas de Ordem Superior Motor de Indução.

1. INTRODUÇÃO

Motores elétricos possuem uma ampla área de aplicabilidade na indústria, devido à sua robustez e simplicidade de comando. Dado seu largo uso nas plantas industriais, desenvolver melhores métodos de diagnosticar possíveis falhas de modo preciso e eficaz de assegurar uma melhor manutenção destes aparelhos é de suma importância para garantir a produtividade, manter a segurança da planta e reduzir os custos de manutenção. Dada esta problemática, outros modelos de manutenção precisam ser aplicados, além da tradicional manutenção corretiva, como a manutenção preditiva, também denominada manutenção baseada na condição (Liao and Wang, 2013).

Dentre as ocorrências de falhas ocorridas em motores de indução, as falhas em rolamentos correspondem 44 % do total, como visto em Gongora et al. (2016). Baseando-se nisto, propor um método que além de detectar as falhas em rolamentos, indicar sua gravidade, têm sua importância no cenário industrial, sendo este cada vez mais cognitivo por meio de tecnologias como a indústria 4.0 e o uso

⋆ Este trabalho teve suporte financeiro dos órgãos de fomento Capes,CNPq, FAPEMIG e UFLA.

de ferrramentas de Internet das Coisas (IoT, do inglês *Internet of things*) (Thoben et al., 2017).

Imerso no cenário de manutenção preditiva, encontram-se muitos autores com diferentes abordagens e aplicações a fim de resolver tais problemas. A exemplo, o método baseado em redes neurais artificiais para detectar e classificar as falhas em rolamentos proposto por Gongora et al. (2016). Em Yang et al. (2004), os autores propuseram uma abordagem utilizando raciocínio baseado em casos (CBR, do inglês *Case-based reasoning*), que é uma técnica que resolve determinado problema com as soluções de problemas passados, com o uso de rede de Petri para diagnostico de falhas em motores de indução. A fim de diagnosticar falhas iniciais, Darong et al. (2018) apresentam um método de mínimos quadrados recursivos (RLS, do inglês *recursive least squares*) e uso de algoritmo de decomposição de média local (LMD, do inglês *local mean decomposition*). Outra técnica foi feita com o uso de monitores de circuito que detecta frequências de vibrações aplicando a decomposição de pacotes Wavelets e rede neural de base radial, com o intuito de encontrar falhas em motores em estágio inicial (Devaney and Eren, 2004). Neste outro caso, realiza-se a detecção e o monitoramento das falhas com base em curtose spectral (SK, do inglês *spectral kurtosis*) e na correlação cruzada, com o uso do método k-vizinhos (Tian et al., 2015). Outro exemplo de detecção e classificação de falhas pode ser visto em Vives et al. (2020), onde os autores propuseram o uso de técnicas de aprendizagem de máquina como o SVM (*Support Vector Machines*) e o k-vizinhos mais próximos para análise de falhas em rolamentos de uma turbina eólica.

Neste artigo é proposto um método para classificação de falhas em um motor de indução trifásico (MIT). Usando como objeto de estudo, análises de rolamentos em três condições diferentes, rolamento sem falha, rolamento com falha na pista externa e falha nas duas pistas. Os dados analisados foram sinais de vibração coletados por um acelerômetro de 3 eixos acoplado ao motor e aquisitados por meio de uma placa Arduino. A partir dos sinais coletados, foram extraídos parâmetros dos sinais por meio de estatísticas de Ordem Superior (EOS) (Mendel, 1991).As EOS apresentam boa caracterização de sinais de vibração como visto em Barbosa et al. (2016). Para classificação de falhas, foram utilizadas Curvas Principais (Hastie and Stuetzle, 1989) por meio do algoritmo k-segmentos (Verbeek et al., 2001). As Curvas Principais apresentam bons resultados em problemas de reconhecimento de padrões, tais como classificação de navios (Fernandez, 2005), análise de qualidade de energia elétrica (Ferreira et al., 2015) e problemas de clusterização (Moraes et al., 2020).

2. MÉTODO PROPOSTO

O método proposto é composto por 4 etapas: aquisição de sinais de vibração do motor, extração de parâmetros, o projeto do classificador e a análise dos resultados. A ideia central está exemplificada pela Figura 1.

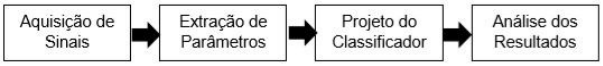

Figura 1. Fluxograma do método proposto.

2.1 Aquisição de sinais

A aquisição de sinais de vibração do motor foi obtida utilizando um motor de indução trifásico KOHLBACH® de 2 CV, tensão de alimentação 380 V e rotação nominal de 3.480 rpm. O motor foi acionado por partida direta, operado a vazio e com velocidade nominal. Foram utilizados rolamentos em três condições distintas, rolamento sem falha, com falha na pista externa, e com falha nas duas pistas do rolamento. Cada falha foi induzida em laboratório por meio de um furo nas pistas citadas anteriormente. Os rolamentos utilizados foram de modelo NSK 6204, como mostrado na Figura 2.

Figura 2. Rolamento sem falha (à esquerda); Rolamento com falha na pista externa (ao centro); Rolamento com falha nas duas pistas (à direita).

A coleta foi realizada por meio de um acelerômetro micromecanizado de 3 eixos, modelo MMA 7361, com o sensor acoplado na tampa dianteira do motor, abaixo do eixo de rotação. O eixo definido para coleta foi o eixo X, devido à experimentos preliminares mostrarem este eixo com maior capacidade de discriminação. Na Figura 3 e apresentada a montagem do acelerômetro no motor e a montagem de todo o experimento em bancada é mostrada na Figura 4. Vinculado a uma placa Arduino modelo MEGA 2560, cada coleta foi realizada com 2 minutos de duração e 24.000 amostras coletadas (operando em uma taxa de aquisição de 200Hz). Esses dados foram armazenados em planilhas, para processamento posterior no *software* MatLab.

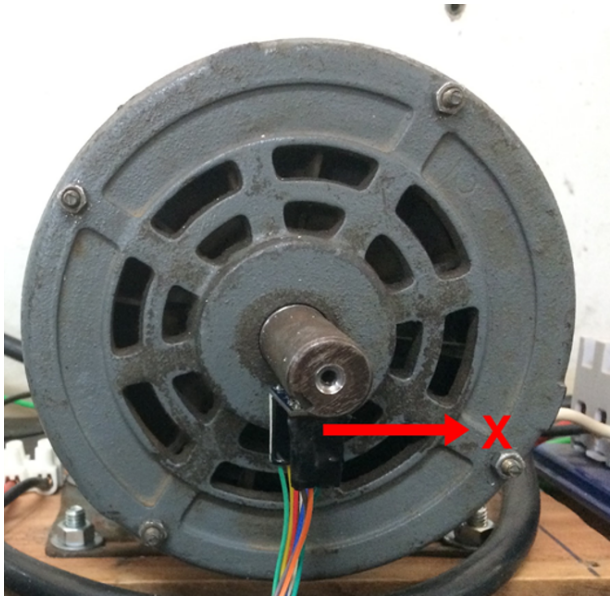

Figura 3. Acoplamento do acelerômetro no motor e representação do eixo coletado.

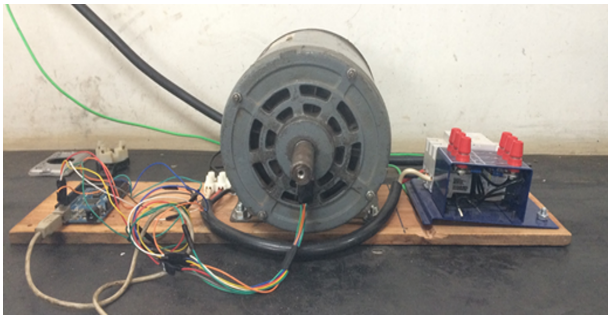

Figura 4. Montagem do experimento em bancada.

2.2 Extração de Parâmetros

Para a extração de parâmetros, utilizou-se estatísticas de ordem superior (EOS) (Mendel, 1991). Seu uso se deu à robustez das EOS a ruídos e a boa capacidade de representação de sinais de vibração como mostrado em Barbosa et al. (2016). Utilizaram-se aproximações estocásticas de cumulantes de segunda e quarta ordens no atraso nulo para vetores de comprimento finito (Barbosa et al., 2016). As formulações estão expressas nas equações (1) e (2):

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

$$\widehat{C}_{4,x}[0] := \frac{2}{N}\sum_{n=0}^{N} x[n]x^3[mod[n,N]] - \frac{2}{N^2}\sum_{n=0}^{N} x[n]x[mod[n,N]]\sum_{n=0}^{N} x^2[n] \tag{2}$$

Onde N é o comprimento do vetor de entrada x, e $mod[n,N]$ é o resto da divisão da posição n por N.

2.3 Projeto do Classificador

Curvas Principais: São uma generalização não linear da análise de componentes principais (PCA, do inglês *Principal Component Analysis*) inicialmente desenvolvida por Hastie and Stuetzle (1989). As Curvas principais possuem a capacidade de fornecer reprensentações unidimensionais de conjuntos de dados multidimensionais, gerando, assim, modelos compactos de grandes conjuntos de dados.

Baseando-se na proposta inicial de Hastie and Stuetzle (1989), algoritmos alternativos foram explorados e desenvolvidos a fim de se obter melhores extrações das CP, de maneira que apresentassem uma convergência prática e desempenho computacional satisfatório, como por exemplo, o algoritmo K-segmentos proposto por Verbeek et al. (2001). Tal algoritmo possui menor influência a mínimos locais e convergência prática garantida, fornecendo, assim, robustez ao método. O algoritmo k-segmentos é dividido em 3 passos a seguir e um fluxograma de seu algoritmo é apresentado na Figura 5.

(0) Nesta etapa obtém-se o primeiro segmento utilizando todo o conjunto de dados do sistema. O segmento é obtido na direção da primeira componente principal com comprimento de 3/2 de desvio padrão dos dados.

(1) Um segundo segmento é adicionado a um novo agrupamento feito por meio do algoritmo *k-means*, com base nas regiões de Voronoi, neste contexto, essas regiões são onde os eventos de um dado agrupamento, por sua vez estão com maior proximidade do centro regional que dos segmentos da curva. Depois de realizado a obtenção do segundo segmento, é feito o cálculo novamente do primeiro segmento, em razão de uma modificação no seu agrupamento. Esse mesmo processo é feito para os demais segmentos, adicionando-se um novo segmento e realizando o recalculo dos segmentos onde houve mudança em seu agrupamento.

(2) É realizado o teste de convergência do algoritmo de dois modos. Primeiro verifica-se se o número de segmentos k alcançou o valor máximo de segmentos esperado pelo usuário (K_{max}), ou se o maior agrupamento concebido possui ao menos, 3 segmentos. Se estiver em desacordo com as duas condições estabelecidas, o algoritmo retorna ao Passo 1.

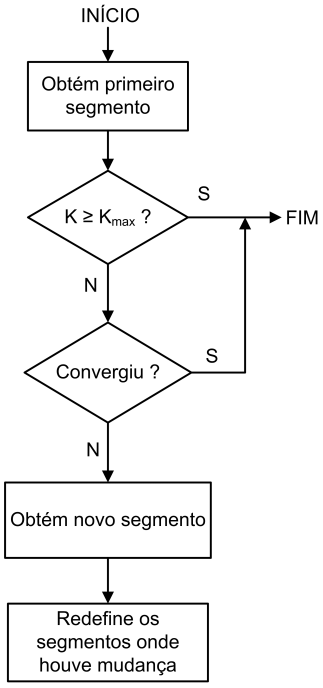

Figura 5. Fluxograma do algoritmo k-segmentos para obtenção de CP.

Curvas Principais como Classificador: Para o projeto do classificador, foi utilizada uma abordagem supervisionada de um classificador por meio de Curvas Principais. Para isto, foi obtidas uma Curva Principal para cada uma das classes (sendo estas referentes às 3 condições do rolamento: sem falha, com falha em 1 pista e com falha nas 2 pistas).

A partir da extração das Curvas para cada padrão referente à condição do rolamento, foi aplicada a seguinte regra de classificação: para cada novo evento, são calculadas as distâncias deste evento à cada uma das Curvas referentes à cada classe e o evento é classificado como Curva o que obter a menor distância. Uma forma de ilustrar o funcionamento desta regra pode ser vista na Figura 6.

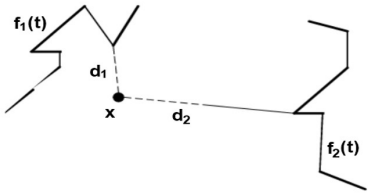

Figura 6. Exemplo da regra de classificação.

3. RESULTADOS E DISCUSSÃO

Após as coletas dos sinais de vibração, os sinais contendo 24.000 amostras foram divididas em eventos contendo 1.500 amostras cada que serão utilizados nas etapas posteriores. Os sinais foram normalizados removendo-se a média e dividindo pelo seu máximo absoluto. Os sinais regularizados de um evento selecionado aleatoriamente para o motor com rolamento sem falha, com falha em 1 pista e com falha em 2 pistas, estão contidos, respectivamente, nas Figuras 7, 8 e 9.

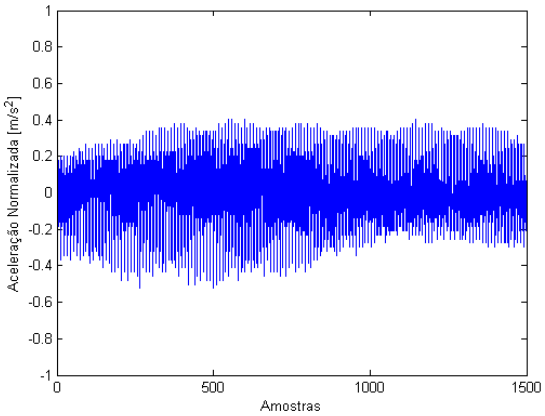

Figura 7. Sinal normalizado de um evento para o motor com rolamento sem falha.

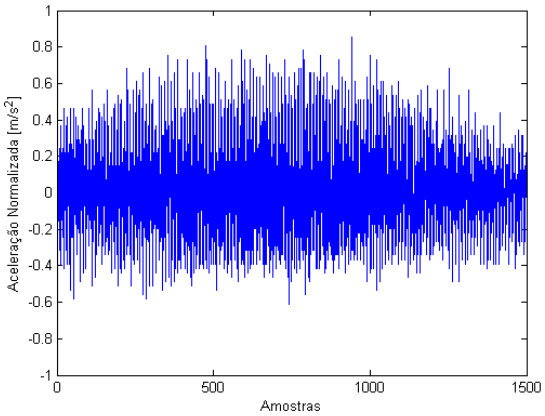

Figura 8. Sinal normalizado de um evento para o motor com rolamento com falha em 1 pista

Concluída a aquisição de sinais, foram extraídos os cumulantes de segunda e quarta ordens com atraso nulo e posteriormente foram geradas as Curvas Principais. Foram

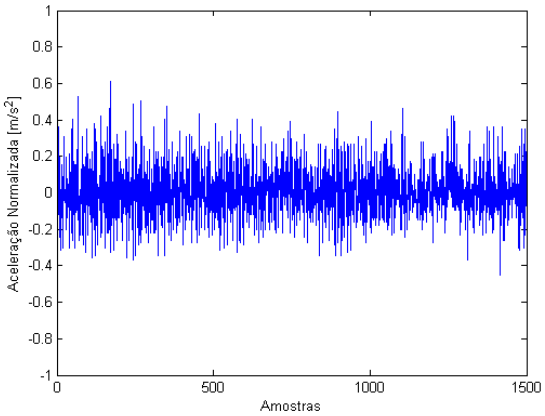

Figura 9. Sinal normalizado de um evento para o motor com rolamento com falha em 2 pistas

testadas 3 topologias de CP com 5, 10 e 15 segmentos variando o tamanho do conjunto de desenvolvimento da curva de 50 a 250 eventos em intervalos de 50, de acordo com cada topologia. Com o intuito de avaliar qual apresentaria melhor desempenho e menor custo computacional. Para isto, foram realizadas 100 execuções da rotina do classificador selecionando, em cada uma destas, aleatoriamente, os conjuntos de treino e teste. Assim, são obtidas como medidas de avaliação do método, as taxas de acerto médias (μ) e seus respectivos desvios-padrão (σ). O espaço de parâmetros dos cumulantes contendo todo o conjunto de dados e suas respecitvas CP é mostrado na Figura 10 e os resultados do classificador com taxas de acerto referente aos modelos com 5, 10 e 15 segmentos para variados tamanhos de conjunto de dados N_t estão apresentados nas respectivas Tabelas 1, 2 e 3.

Com base nos resultados obtidos apresentados na Figura 10 e nas Tabelas 1, 2, 3, nota-se que os resultados de treino e teste para a classe de falha em uma pista tiveram taxas de acerto de 100% justamente por sua separação linear desta classe para as demais, em consequência das classes de rolamentos sem falha e falha nas duas pistas não serem separáveis, e portanto apresentam resultados menores que os 100% como na classe de falha em 1 pista.

Os resultados apresentaram altas taxas de acerto mesmo com pequenos conjuntos de treinamento. Isto implica que consideráveis resultados poderiam ter em aplicações *on-line*, já que pequenos conjuntos de treinamento significam menor tempo de processamento para o projeto do classificador em questão.

Outro ponto a se destacar é que o aumento do conjunto de dados não necessariamente implica em maiores taxas de acerto ou redução dos desvios-padrão. Os resultados quantitativos apresentados não possuem dependência direta com o aumento do conjunto de treino ou aumento da complexidade das Curvas Principais. Dentre as topologias apresentadas e os tamanhos dos conjuntos de treinamento a que apresentou melhor desempenho, quando se analisa a maior taxa de acerto e o menor desvio-padrão em teste, foi a topologia de 10 segmentos cujo conjunto de dados de treino $N_t = 200$. Entretanto a topologia com 5 segmentos também apresentou bons resultados e possui menor custo

computacional, mesmo com menor complexidade obteve resultados próximos a topologia de 10 segmentos.

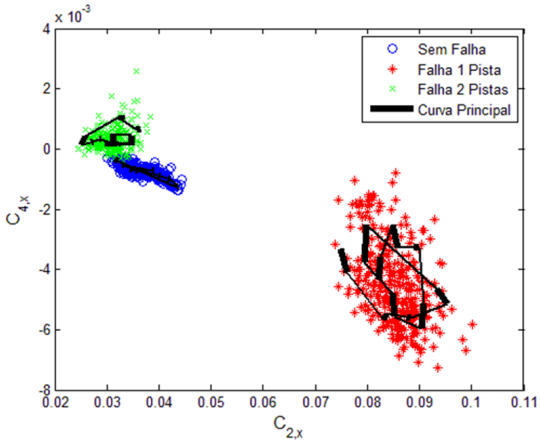

Figura 10. Espaço de parâmetros obtido através dos cumulantes contendo todo o conjunto de dados.

Tabela 1. Taxas de acerto [%] para topologia de 5 segmentos ($\mu \pm \sigma$)

N_t	Classe Sem falha		Classe falha 1 pista		Classe Falha 2 pistas	
	Treino	Teste	Treino	Teste	Treino	Teste
50	98,68 ± 1,46	98,02 ± 1,71	100,00 ± 0,00	100,00 ± 0,00	97,76 ± 1,80	96,76 ± 1,49
100	98,55 ± 1,37	98,22 ± 1,37	100,00 ± 0,00	100,00 ± 0,00	97,93 ± 1,24	97,67 ± 1,19
150	98,77 ± 0,94	98,74 ± 0,91	100,00 ± 0,00	100,00 ± 0,00	97,74 ± 0,95	97,70 ± 0,94
200	98,90 ± 0,54	98,93 ± 0,84	100,00 ± 0,00	100,00 ± 0,00	97,58 ± 0,79	97,61 ± 1,26
250	98,91 ± 0,44	98,77 ± 1,15	100,00 ± 0,00	100,00 ± 0,00	97,38 ± 0,78	97,26 ± 1,81

Tabela 2. Taxas de acerto [%] para topologia de 10 segmentos ($\mu \pm \sigma$)

N_t	Classe Sem falha		Classe falha 1 pista		Classe Falha 2 pistas	
	Treino	Teste	Treino	Teste	Treino	Teste
50	99,10 ± 1,22	98,40 ± 1,26	100,00 ± 0,00	100,00 ± 0,00	98,00 ± 1,84	96,51 ± 1,53
100	99,03 ± 0,92	98,71 ± 0,83	100,00 ± 0,00	100,00 ± 0,00	98,28 ± 1,39	97,90 ± 1,04
150	98,93 ± 0,84	98,87 ± 0,85	100,00 ± 0,00	100,00 ± 0,00	98,31 ± 1,20	98,31 ± 1,08
200	98,99 ± 0,65	99,12 ± 0,81	100,00 ± 0,00	100,00 ± 0,00	98,41 ± 0,74	98,41 ± 1,06
250	98,96 ± 0,66	98,91 ± 1,45	100,00 ± 0,00	100,00 ± 0,00	98,50 ± 0,62	98,50 ± 1,52

Tabela 3. Taxas de acerto [%] para topologia de 15 segmentos ($\mu \pm \sigma$)

N_t	Classe Sem falha		Classe falha 1 pista		Classe Falha 2 pistas	
	Treino	Teste	Treino	Teste	Treino	Teste
50	99,20 ± 1,10	98,27 ± 1,08	100,00 ± 0,00	100,00 ± 0,00	98,04 ± 1,71	96,46 ± 1,68
100	99,06 ± 1,08	98,87 ± 0,80	100,00 ± 0,00	100,00 ± 0,00	98,14 ± 1,18	97,40 ± 1,18
150	99,04 ± 0,80	99,05 ± 0,79	100,00 ± 0,00	100,00 ± 0,00	98,12 ± 1,32	98,04 ± 1,33
200	98,94 ± 0,67	98,97 ± 0,92	100,00 ± 0,00	100,00 ± 0,00	98,43 ± 1,15	98,46 ± 1,29
250	98,89 ± 0,53	98,90 ± 1,13	100,00 ± 0,00	100,00 ± 0,00	98,76 ± 0,90	98,77 ± 1,38

4. CONCLUSÕES E PERSPECTIVAS

De acordo com os resultados obtidos, e análises realizadas anteriormente, nota-se que este método apresentou bons resultados com taxas de acerto acima de 95%, e com baixo custo computacional, principalmente na fase operacional em que basta calcular as distâncias do evento à curva e atribuí-lo à classe em que obteve menor distância. O método apresentou, também, resultados satisfatórios com baixos conjuntos de treinamento, o que mostra uma boa capacidade de generalização das Curvas Principais. Além dos bons resultados de desempenho no modelo classificador, o método possui baixos custos de operação. Uma vez que o sistema de aquisição de dados é composto por equipamentos de baixo custo e *hadrware open-source* (placa Arduino e sensor acelerômetro). Para os próximos trabalhos visa-se a submissão do motor a cargas e uma análise com maior aprofundamento do estudo das falhas e uma possível aplicação *online*. Com o objetivo de melhorar o método, garantindo uma melhor qualidade e segurança nas linhas de produção.

AGRADECIMENTOS

Agradecimento à CAPES, FAPEMIG, UFLA e CNPq pelo suporte financeiro à este trabalho e à Bobinadora Lavrense pelo empréstimo do motor utilizado no experimento.

REFERÊNCIAS

Barbosa, T.S., Ferreira, D.D., Pereira, D.A., Magalhães, R.R., and Barbosa, B.H. (2016). Fault detection and classification in cantilever beams through vibration signal analysis and higher-order statistics. *Journal of Control, Automation and Electrical Systems*, 27(5), 535–541.

Darong, H., Lanyan, K., Bo, M., Ling, Z., and Guoxi, S. (2018). A new incipient fault diagnosis method combining improved rls and lmd algorithm for rolling bearings with strong background noise. *IEEE Access*, 6, 26001–26010.

Devaney, M.J. and Eren, L. (2004). Detecting motor bearing faults. *IEEE Instrumentation & Measurement Magazine*, 7(4), 30–50.

Fernandez, H.L. (2005). *CLASSIFICAC AO DE NAVIOS BASEADA EM CURVAS PRINCIPAIS*. Ph.D. thesis, UNIVERSIDADE FEDERAL DO RIO DE JANEIRO.

Ferreira, D.D., de Seixas, J.M., Cerqueira, A.S., Duque, C.A., Bollen, M.H., and Ribeiro, P.F. (2015). A new power quality deviation index based on principal curves. *Electric Power Systems Research*, 125, 8–14.

Gongora, W.S., Goedtel, A., da Silva, S.A.O., and Graciola, C.L. (2016). Neural approach to fault detection in three-phase induction motors. *IEEE Latin America Transactions*, 14(3), 1279–1288.

Hastie, T. and Stuetzle, W. (1989). Principal curves. *Journal of the American Statistical Association*, 84(406), 502–516.

Liao, W. and Wang, Y. (2013). Data-driven machinery prognostics approach using in a predictive maintenance model. *JCP*, 8(1), 225–231.

Mendel, J.M. (1991). Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications. *Proceedings of the IEEE*, 79(3), 278–305.

Moraes, E.C.C., Ferreira, D.D., Vitor, G.B., and Barbosa, B.H.G. (2020). Data clustering based on principal curves. *Advances in Data Analysis and Classification*, 14(1), 77–96.

Thoben, K.D., Wiesner, S., and Wuest, T. (2017). "industrie 4.0" and smart manufacturing-a review of research issues and application examples. *International journal of automation technology*, 11(1), 4–16.

Tian, J., Morillo, C., Azarian, M.H., and Pecht, M. (2015). Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with k-nearest neighbor distance analysis. *IEEE Transactions on Industrial Electronics*, 63(3), 1793–1803.

Verbeek, J.J., Vlassis, N., and Kröse, B. (2001). A soft k-segments algorithm for principal curves. In *International Conference on Artificial Neural Networks*, 450–456. Springer.

Vives, J., Quiles, E., and García, E. (2020). Ai techniques applied to diagnosis of vibrations failures in wind turbines. *IEEE Latin America Transactions*, 18(08), 1478–1486.

Yang, B.S., Jeong, S.K., Oh, Y.M., and Tan, A.C.C. (2004). Case-based reasoning system with petri nets for induction motor fault diagnosis. *Expert Systems with Applications*, 27(2), 301–311.