

ANÁLISE DE AVARIAS EM ROLAMENTOS, UTILIZANDO ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL

ANDRÉ DA SILVA BARCELOS,* FÁBIO MUNIZ MAZZONI,† ANTÓNIO JOÃO MARQUES CARDOSO*

* *CISE-Electromechatronic Systems Research Centre
University of Beira Interior, Covilhã, Portugal*

† *Universidade Federal Fluminense
Rio de Janeiro, Brasil*

Emails: andre.s.barcelos@ubi.pt, fabiomuma@hotmail.com, ajmcardoso@iee.org

Abstract— Three-phase induction motors are used on a large scale, where it is known that the maintenance of these machines is preponderant for the continuity of industrial processes. Recent research shows that bearing failures are recurrent and it is necessary to develop techniques for analyzing, predicting and diagnosing these failures. In this context, this work calculates the Daubechies wavelets and Hilbert-Huang transforms of the current signals of a three-phase induction motor both in normal condition and with failures. Then, statistical tools are used to extract characteristics from the transformed signals, with the purpose of creating a database to analyze and diagnose malfunctions, with artificial intelligence algorithms. Results show that it is possible to classify failures in bearings, using the proposal developed in this work, with a performance higher than 98 %.

Keywords— Three-phase Induction Motor, Bearing Failures Identification, Time-frequency Transforms, Artificial Intelligence

Resumo— Os motores de indução trifásicos são utilizados em larga escala, onde sabe-se que a manutenção destas máquinas é preponderante para a continuidade de processos industriais. Pesquisas recentes apontam, que as avarias nos rolamentos são recorrentes e que se torna necessário desenvolver técnicas para análise, previsão e diagnóstico destas avarias. Neste contexto, este trabalho calcula as transformadas wavelet de Daubechies e Hilbert-Huang dos sinais de corrente de um motor de indução trifásico, quer para a condição normal de funcionamento e quer com avarias. Em seguida, utilizam-se ferramentas estatísticas para extrair as características dos sinais transformados, tendo como finalidade a criação de uma base de dados para analisar e diagnosticar avarias, com auxílio de algoritmos da inteligência artificial. Os resultados apontam que é possível classificar avarias em rolamentos, utilizando a proposta desenvolvida neste trabalho, com um desempenho superior a 98%.

Palavras-chave— Motor de indução trifásico, identificação de falhas em rolamentos, transformadas no domínio tempo-frequência, inteligência artificial

1 Introdução

A conversão de energia elétrica em mecânica está presente nos processos industriais, onde os motores de indução trifásicos (MITs), são responsáveis por acionar equipamentos, tais como bombas, válvulas, esteiras, hélices, elevadores, entre outros. Devido ao custo reduzido de fabricação e a versatilidade para aplicações com alto rendimento, estima-se que 70% da energia consumida no setor industrial da União Europeia, está diretamente relacionada com a utilização de motores elétricos trifásicos (Merizalde et al., 2017).

Devido às características de construção e operação do MIT, avarias quer elétricas quer mecânicas podem ocorrer nessas máquinas, acarretando redução de desempenho ou interrupção de processos industriais (Cerrada et al., 2018). Os estudos publicados pelos *Institute of Electrical and Electronics Engineers (IEEE)* e *Electric Power Research Institute (EPRI)*, apontam as falhas encontrados nos MITs conforme Tabela 1.

As principais falhas mecânicas nos MITs, são causadas por impactos, devido à fricção do rotor com o estator, desgaste, danos durante a montagem, sobreaquecimento, quebra de barras, falhas nas pistas externa, interna e esferas dos rolamen-

Tabela 1: Percentual de falhas no MIT de acordo com a EPRI e IEEE

	Falha nos rolamentos	Falhas elétricas	Outros
EPRI	42%	48%	10%
IEEE	40%	36%	24%

tos, desalinhamento, lubrificação insuficiente, torção e sobrecarga do eixo (Cardoso, 1991; Merizalde et al., 2017).

Para identificar avarias mecânicas no MIT, torna-se necessário adquirir variáveis de natureza mecânica, elétrica ou térmica em uma etapa determinada aquisição da sinais. Em seguida, utilizam-se técnicas de processamento de sinais, como a transformada de Fourier para sinais estacionários e waveletes ou Hilbert-Huang, para sinais não-estacionários (Bessous et al., 2018). Os três primeiros blocos da Figura 1, resumem essas etapas.

A extração de características recorre a ferramentas estatísticas, com objetivo de formar uma base de dados, que reflete o comportamento do MIT em condições de avarias. Ao final, utilizam-se algoritmos da inteligência artificial (IA), na condição de sistema especialista, para análise e diag-



Figura 1: Etapas para a análise e diagnóstico de avarias em motores.

nóstico, (Bazan et al., 2017).

Para descrever a metodologia adotada para diagnosticar avarias em rolamentos, a seção 2 apresenta o rolamento e as características associadas. Ainda nesta seção, são descritas as transformadas wavelet (TW) e Hilbert-Huang (THH), que são utilizadas na etapa de processamento de sinais. Em seguida descreve-se uma máquina de vetor de suporte (MVS) e uma rede neural artificial (RNA) para a etapa de diagnóstico.

Na seção 3, definem-se as bases de dados, as medidas estatísticas e os parâmetros dos algoritmos de IA. Na seção 4 apresentam-se os resultados obtidos na identificação de avarias dos rolamentos, com desempenho superior a 96% em todos os algoritmos, por último as principais conclusões encontram-se na seção 5.

2 Base teórica

2.1 Avarias em rolamentos

No momento em que um MIT gira com uma avaria no rolamento, surgem frequências associadas, que são percebidos nas correntes do rotor e do estator. A Figura 2, apresenta um rolamento, onde se encontram representados os detalhes geométricos necessários, para descrever as equações do funcionamento e as frequências típicas que estão associadas às avarias (Rao et al., 2019).

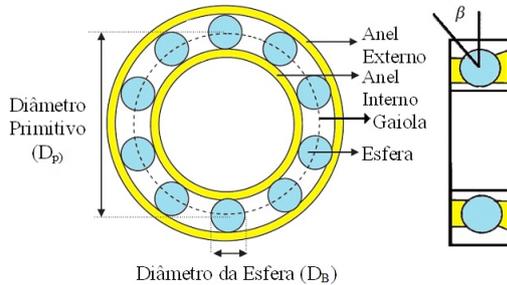


Figura 2: Detalhes geométricos de um rolamento com 10 esferas.

No trabalho de (Silva and Cardoso, 2005a; Silva and Cardoso, 2005b), encontram-se os detalhes para a obtenção das equações 1, 2, e 3, as

avarias nas pistas externas, interna e ainda nas esferas.

$$f_o = \frac{N_b}{2} f_r \left(1 - \frac{D_b}{D_p} \cos \beta \right) \quad (1)$$

$$f_i = \frac{N_b}{2} f_r \left(1 + \frac{D_b}{D_p} \cos \beta \right) \quad (2)$$

$$f_b = \frac{D_b}{D_l} f_r \left(1 - \frac{D_b^2}{D_p^2} \cos^2 \beta \right) \quad (3)$$

onde:

f_o frequência típica da pista externa (Hz);

f_i frequência típica da pista interna (Hz);

f_b frequência típica das esferas (Hz);

f_r frequência de rotação do motor (Hz);

D_p diâmetro primitivo (mm);

D_b diâmetro da esfera (mm);

N_b número de esferas;

β ângulo de contato.

O trabalho de (Bessous et al., 2018), propõe que as equações 1 e 2, podem ser aproximadas pelas expressões 4 e 5, para rolamentos de 6 a 12 esferas que são encontrados na maioria das aplicações.

$$f_o = 0.4N_b f_r \quad (4)$$

$$f_i = 0.6N_b f_r \quad (5)$$

2.2 Transformada wavelet

A transformada de Fourier (FT) é utilizada na etapa de processamento de sinais, para adquirir informações de sinais estacionários, no domínio da frequência. Adaptações nesta transformada, como a Short-Time Fourier Transform (STFT), permite a utilização de uma janela de amostragem fixa, que localiza as informações no domínio do tempo-frequência em resolução constante (Aimer et al., 2019).

Em muitas aplicações, a utilização da STFT torna-se inadequada, pois os sinais de corrente do MIT em condição de avaria, apresentam variações dinâmicas na frequência que caracterizam um sinal não-estacionário. (Bessous et al., 2018). Para o processamento de sinais não-estacionários, utilizam-se transformadas em multiresolução que constroem janelas de amostragem de largura variável, no domínio do tempo-frequência (Kamiel and Howard, 2019).

Nesse contexto, a transformada wavelet consegue atender à necessidade de multiresolução, para processamento de sinais não-estacionários no domínio tempo-frequência, pois esta transformada possibilita a utilização de janelas de amostragem de largura variável, de acordo com cada evento no tempo (Gupta et al., 2019). A Equação 6 expressa o produto interno entre o sinal amostrado e a wavelet.

$$\langle f(t), \psi_{a,b}(t) \rangle = \frac{1}{\sqrt{a}} \int f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (6)$$

em que $\langle \cdot \rangle$ denota o produto interno, a função ψ é a wavelet, os parâmetros a e b são os fatores de escalonamento e translação. A alteração do parâmetro a , possibilita o escalonamento das janelas de amostragem do sinal $f(t)$.

Para uma função $\psi_{a,b}$ ser definida como wavelet, ela deve pertencer ao espaço L^2 (espaço das funções integráveis em Lebesgue, em que o seu quadrado também seja), possuir regularidade e energia finita conforme as equações 7 e 8.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (7)$$

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty \quad (8)$$

2.3 Transformada wavelet discreta

A transformada wavelet discreta (TWD) da função $\psi_{a,b}$, é obtida ao definir que os parâmetros a e b são inteiros em um intervalo fechado. Ao fazer com que o parâmetro b seja dependente de a , chega-se a expressão de uma wavelet $\psi_{m,n}$ com fatores de escalonamento e translação inteiros, conforme as Equações 9 e 10, onde m e n são inteiros que devem ser escolhidos de acordo com a forma da wavelet.

$$\psi_{m,n}(t) = a_0^{-m/2} \psi(a_0^{-m} t - nb_0) \quad (9)$$

$$DWT_{m,n} = \frac{1}{\sqrt{a^m}} \sum_{k=-\infty}^{+\infty} f(k) \psi\left(\frac{w(t)}{a^m}\right) \quad (10)$$

$$w(t) = t - nb_0 a_0^m \quad (11)$$

2.3.1 Interpretação da wavelet

O produto interno entre o sinal $f(t)$ e a wavelet $\psi_{a,b}(t)$, produz coeficientes que constituem um sinal transformado (S). Este sinal é decomposto através de filtros passa-alta e passa-baixa, para gerar dois novos sinais, que contém o conjunto de coeficientes $g[k]$ (passa-alta) e $h[k]$ (passa-baixa). (Bayro-Corrochano, 2019).

Para construção destes filtros, o parâmetro de escalonamento é redefinido para uma função $\phi(t)$, que depende dos coeficientes da filtragem $h[k]$ conforme Equação 12. A função $\psi_{a,b}(t)$ é redefinida para depender da função de escalonamento e de $g[k]$, conforme a Equação 13 (Gupta et al., 2019).

$$\phi(t) = \sqrt{2} \sum_{k \in Z} h[k] \phi(2t - k) \quad (12)$$

$$\psi(t) = \sqrt{2} \sum_{k \in Z} g[k] \phi(2t - k) \quad (13)$$

Desta forma, o sinal S é dividido em duas bandas de filtragem, onde a banda passa-baixas (LP), é formada pelo sinal $h[k]$ e recebe o nome de coeficientes de aproximação (cA). A banda passa-altas (HP), é formada por $g[k]$ e recebe o nome de coeficientes dos detalhes (cD) (Bessous et al., 2018).

A decomposição em multiresolução, consiste em utilizar o cA do sinal S, em sucessivas transformadas DWT, com a finalidade de extrair diversos níveis de detalhes, conforme a Figura 3.

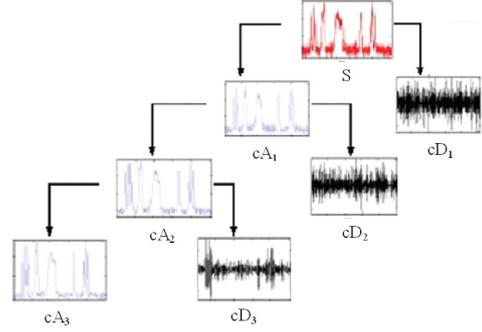


Figura 3: Decomposição do sinal amostrado S em três níveis de Aproximações e Detalhes

Torna-se necessário definir o último nível em que a decomposição cD extrai detalhes do sinal amostrado, sem redundância da informação. Os teoremas explicados em (Bessous et al., 2019) e (Ghods and Lee, 2016) definem um critério de finalização para a decomposição sucessiva, conforme Equação 14.

$$N = \text{int} \left[\frac{\log\left(\frac{f_a}{f_f}\right)}{\log(2)} \right] + 1 \quad (14)$$

Onde N é o nível máximo de detalhamento, f_a é a frequência da amostragem e f_f é a frequência do motor. Evidencia-se que os níveis cD, dependem da taxa de amostragem.

2.3.2 Wavelets de Daubechies

As wavelets propostas por Daubechies em seu trabalho original (Daubechies, 1988), são funções $\psi(t)$ em bases ortonormais, com suporte compacto, regularidade e número máximo de momentos nulos (Gupta et al., 2019). A Figura 4 apresenta a wavelet de Daubechies de ordem N=12 (D12), com $N/2 = 6$ momentos nulos e suporte compacto $N-1 = 11$.

Observa-se que a D12 possui máximo e mínimo definidos, energia finita, limita-se ao suporte e tem média zero, conforme equações 7 e 8. O momento nulo, relaciona-se com a suavidade da

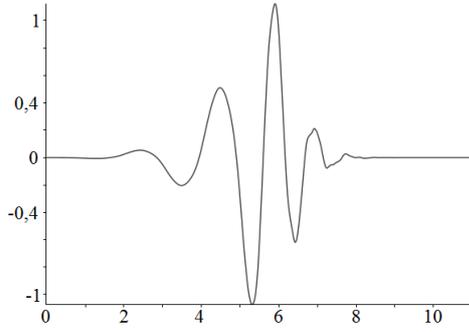


Figura 4: Esboço de uma wavelet D12

resposta em frequência e a capacidade de representar polinômios. Para definir a existência de k momentos nulos, a Equação 15 deve ser satisfeita (Narendiranath et al., 2017).

$$\int x^k \psi(x) dx = 0 \quad (15)$$

As propriedades que determinam a escolha de wavelets de Daubechies, são a ortogonalidade, máximo e mínimo definidos e a quantidade máxima de momentos nulos em suporte compacto. Por definição, suporte compacto é um intervalo fechado que contém toda a energia da função. Fora deste intervalo a energia deve ser zero ou exponencialmente decrescente (Narendiranath et al., 2017).

2.4 Transformada de Hilbert-Huang

A transformada de Hilbert-Huang (HHT) decompõe um sinal amostrado no plano complexo e torna-se adequada para sinais não-estacionários (Bessous et al., 2019), onde se utilizam as equações 16 e 17 para a obter HHT do sinal (s).

$$H(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{s(\tau)}{t - \tau} d\tau \quad (16)$$

$$z(t) = s(t) + iH(t) = a(t)e^{i\theta(t)} \quad (17)$$

onde $H(t)$ é a HHT, i é o número imaginário e P representa o valor principal de Cauchy.

Para calcular a HHT, utiliza-se uma técnica denominada *Empirical Mode Decomposition* (EMD) desenvolvida por Huang e demais pesquisadores (Bessous et al., 2019). Inicialmente, calculam-se os extremos, a média e a função de interpolação de duas curvas envoltentes do sinal amostrado $s(t)$ no domínio do tempo, conforme a Figura 5.

Em seguida, ajusta-se iterativamente a interpolação das envoltórias em cada ponto de máximo e mínimo local, através de uma algoritmo denominado *sifting*, com a finalidade de obter funções conhecidas como *Intrinsic Mode Functions* (IMF). Uma função é definida como IMF de um sinal $s(t)$,

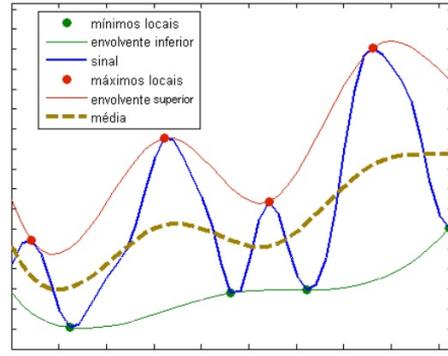


Figura 5: Esboço das envoltórias interpoladas para a EMD

quando a quantidade de zeros, máximos e mínimos são iguais, ou diferem de uma unidade e as duas curvas envoltentes possuem média nula em cada ponto. A Figura 6, apresenta um exemplo de IMF's geradas e o resíduo das interpolações somadas.

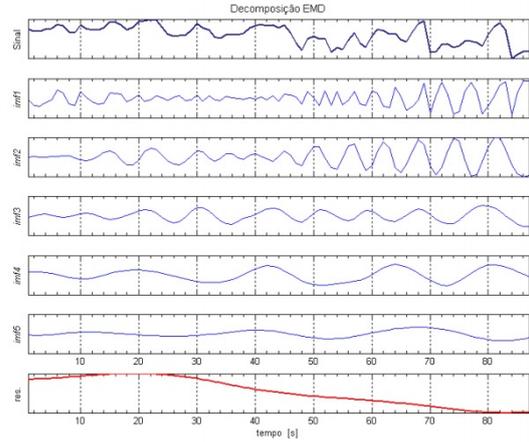


Figura 6: Decomposição de um sinal, IMF's e resíduo em vermelho

Após a obtenção das IMF's, calcula-se a HHT com a finalidade de obter o espectro do sinal no domínio do tempo-frequência. Importa ressaltar que cada IMF contém parte da informação do comportamento do sinal e pode ser utilizada diretamente pelos algoritmos de IA sem que seja necessário calcular a HHT conforme é proposto na seção 3 deste trabalho.

2.5 Rede Neural Artificial

A rede neural artificial (RNA) é uma ferramenta da IA, que estabelece relações não-lineares entre entrada e saída (Witten et al., 2016). Espera-se que a RNA aprenda, através do processo iterativo de ajustes de pesos com minimização de erros de classificação dentro de um critério de finalização (Yegnanarayana, 2009).

2.6 Máquina de Vetor de Suporte

Um algoritmo de máquina de vetor suporte (MVS) desenvolve hiperplanos de complexidade ajustável, com a finalidade de classificação de dados. Desta forma, a MVS é utilizada como classificador multivariável, regressor e identificador de *outliers* (Smola and Schölkopf, 2004).

Os hiperplanos criados estabelecem uma margem de separação para classificação das instâncias da base de dados e posterior generalização. A utilização de um *kernel* permite que a MVS encontre hiperplanos de separação, através de uma transformação não-linear de um espaço de alta dimensionalidade (Witten et al., 2016).

3 Resultados Experimentais

Este trabalho utiliza quatro bases de dados abertas, elaboradas pela *Chair of Design and Drive Technology* da Universidade de Paderborn na Alemanha, para análise de avarias em rolamentos. O trabalho de (Lessmeier et al., 2016) explica como foram realizados os testes e a classificação das bases.

A base de dados K002, contém um motor íntegro e será utilizada na comparação com as bases de motores com avarias em rolamentos. Na base KA07, encontra-se um rolamento avariado com furo pontual, localizado na pista externa, com diâmetro da avaria menor que 2mm.

As bases KI04 e KA08 apresentam um rolamento com corrosão pontual, com diâmetro de avaria menor que 2mm, na pista interna e externa respectivamente. Por último, a base KI18 contém um rolamento com corrosão pontual, com diâmetro de avaria menor que 4mm, na pista interna. Aplica-se a TWD D20, para gerar 6 sinais de detalhes e a EMD para calcular 6 IMF's. Em seguida, extraiu-se a média, média harmônica, curtose, assimetria e entropia dos sinais transformados. Na MVS, utilizou-se o kernel gaussiano (g-MVS) e o polinomial de ordem p $[1, xy, x, y]^p$ (p-MVS). Para o fator complexidade, variou-se exponencialmente o parâmetro c na base 2, até que as classificações atingissem desempenho acima de 96%.

A RNA, inicialmente contém apenas 1 camada oculta, com 12 neurônios e algoritmo de retro-propagação do erro. Para os testes, limitou-se a 1000 épocas, com taxa de aprendizagem entre 0,32 a 0,10, momento entre 0,2 e 0,1, tempo de computação de 0,15 horas e regularização *Lasso*. Realizaram-se alterações na arquitetura da rede, limitadas entre 8 e 16 neurônios na camada oculta.

A seguir, mostram-se os resultados na comparação entre o motor íntegro e o motor com avaria, com os algoritmos wavelet-MVS, wavelet-RNA, EMD-MVS e EMD-RNA. Percebe-se que o treino das redes somente com IMF's, sem efetuar a transformada de Hilbert, apresenta um resultado

relevante.

4 Análise dos Resultados

A concatenação da base de dados (K002, KA07, KI04, KA08 e KI18) gera 20000 instâncias. A Tabela 4, apresenta o desempenho da TWD D20, com 6 decomposições de detalhes em 5 características (30 variáveis).

Tabela 2: Desempenho de classificação com wavelet Daubechies de ordem 20

	KA07	KA08	KI04	KI18
RNA	0,991	0,966	0,962	0,984
p-MVS	0,986	0,974	0,986	0,971
g-MVS	0,970	0,961	0,961	0,975

As classificações com a MVS em kernel gaussiano (g-MVS) apresentam desempenho inferior aos demais. Os algoritmos RNA e a MVS com kernel polinomial $p = 1$, (p-MVS) convergem o treino na ordem de 100 segundos. A Tabela 4 apresenta os resultados obtidos com as 6 IMF's e as mesmas características extraídas (30 variáveis).

Tabela 3: Desempenho de classificação através da EMD e IMF's

	KA07	KA08	KI04	KI18
RNA	0,984	0,998	0,982	0,984
p-MVS	0,988	0,987	0,990	0,991
g-MVS	0,963	0,964	0,978	0,975

Ao comparar as duas tabelas, percebe-se que as duas transformadas apresentam resultados semelhantes. Observa-se que as avarias acentuadas, relacionadas nas bases de dados KA07 e KI18 são classificadas com desempenho superior. Com isto é possível monitorar a tendência de aumento ou degradação de uma avaria, a medida que uma classificação melhora em desempenho.

5 Conclusão

Este trabalho apresenta as bases para a análise de avarias em rolamentos e duas transformadas de sinais não-estacionários, que são a wavelet discreta de Daubechies e a EMD de Hilbert-Huang. Propõe cinco características que devem ser extraídas destes sinais e utiliza uma rede neural artificial e máquinas de vetor de suporte para diagnóstico de avarias.

No final deste trabalho, apresentam-se os resultados obtidos pela classificação e conclui-se que, após os ajustes necessários, é possível classificar as avarias em rolamentos utilizando-se os sinais de corrente elétrica do motor, com desempenho na ordem de 98% de acertos.

Agradecimentos

Este trabalho foi suportado pelo Fundo Europeu para o Desenvolvimento Regional (FEDER) através do Programa Operacional para a Competitividade e a Internacionalização (COMPETE 2020), no âmbito do Projecto POCI-01-0145-FEDER-029494, e por Fundos Nacionais através da Fundação para a Ciência e a Tecnologia (FCT), no âmbito dos Projectos PTDC/EEI-EEE/29494/2017, UIDB/04131/2020 e UIDP/04131/2020. Os autores agradecem ainda à Petrobras Transporte S.A.

Referências

- Aimer, A. F., Boudinar, A. H., Benouzza, N., Bendiabdellah, A. et al. (2019). Bearing fault diagnosis of a pwm inverter fed-induction motor using an improved short time fourier transform, *Journal of Electrical Engineering & Technology* **14**(3): 1201–1210.
- Bayro-Corrochano, E. (2019). Applications of lie filters, quaternion fourier, and wavelet transforms, *Geometric Algebra Applications Vol. I*, Springer, pp. 489–517.
- Bazan, G. H., Scalassara, P. R., Endo, W., Goedtel, A., Godoy, W. F. and Palácios, R. H. C. (2017). Stator fault analysis of three-phase induction motors using information measures and artificial neural networks, *Electric Power Systems Research* **143**: 347–356.
- Bessous, N., Sbaa, S. and Megherbi, A. (2019). Mechanical fault detection in rotating electrical machines using mcsa-fft and mcsa-dwt techniques, *Bulletin of the Polish Academy of Sciences. Technical Sciences* **67**(3).
- Bessous, N., Zouzou, S., Bentrach, W., Sbaa, S. and Sahraoui, M. (2018). Diagnosis of bearing defects in induction motors using discrete wavelet transform, *International Journal of System Assurance Engineering and Management* **9**(2): 335–343.
- Cardoso, A. J. M. (1991). *Diagnóstico de avarias em motores de indução trifásicos*, Universidade de Coimbra.
- Cerrada, M., Sánchez, R.-V., Li, C., Pacheco, F., Cabrera, D., de Oliveira, J. V. and Vásquez, R. E. (2018). A review on data-driven fault severity assessment in rolling bearings, *Mechanical Systems and Signal Processing* **99**: 169–196.
- Daubechies, I. (1988). Orthonormal bases of compactly supported wavelets, *Communications on pure and applied mathematics* **41**(7): 909–996.
- Ghods, A. and Lee, H.-H. (2016). Probabilistic frequency-domain discrete wavelet transform for better detection of bearing faults in induction motors, *Neurocomputing* **188**: 206–216.
- Gupta, K. et al. (2019). *Daubechies wavelets: Theory and applications*, Master’s thesis, Thepar Institute of engineering and technology.
- Kamiel, B. P. and Howard, I. (2019). Ball bearing fault diagnosis using wavelet transform and principal component analysis, **2187**: 50031.
- Lessmeier, C., Kimotho, J. K., Zimmer, D. and Sextro, W. (2016). Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification, *Proceedings of the European conference of the prognostics and health management society*, pp. 05–08.
- Merizalde, Y., Hernández-Callejo, L. and Duque-Perez, O. (2017). State of the art and trends in the monitoring, detection and diagnosis of failures in electric induction motors, *Energies* **10**(7): 1056.
- Narendiranath, B. T., Himamshu, H., Prabin, K. N., Rama, P. D. and Nishant, C. (2017). Journal bearing fault detection based on daubechies wavelet, *Archives of Acoustics* **42**(3): 401–414.
- Rao, S. G., Lohith, S., Gowda, P. C., Singh, A. and Rekha, S. (2019). Fault analysis of induction motor, *2019 IEEE International Conference on Intelligent Techniques in Control, Optimization and Signal Processing (INTCOS)*, IEEE, pp. 1–4.
- Silva, J. L. and Cardoso, A. M. (2005a). Bearing failures diagnosis in three-phase induction motors by extended park’s vector approach, *31st Annual Conference of IEEE Industrial Electronics Society, 2005. IECON 2005.*, IEEE, pp. 6–pp.
- Silva, J. L. and Cardoso, A. M. (2005b). Diagnóstico de avarias nos rolamentos de motores de indução trifásicos, *Universidade de Coimbra*.
- Smola, A. J. and Schölkopf, B. (2004). A tutorial on support vector regression, *Statistics and computing* **14**(3): 199–222.
- Witten, I. H., Frank, E., Hall, M. A. and Pal, C. J. (2016). *Data Mining: Practical machine learning tools and techniques*, Morgan Kaufmann.
- Yegnanarayana, B. (2009). *Artificial neural networks*, PHI Learning Pvt. Ltd.