

Monitoramento de Falhas em Máquinas Elétricas Rotativas Usando Sinais de Vibração e Machine Learning

Lucas de O. Soares¹, Diego A. Lobão¹, Luiz A. Pinto¹

¹Programa de Pós-Graduação em Engenharia de Controle e Automação, Instituto Federal do Espírito Santo
Rodovia ES-010 - Km 6,5 - Manguinhos, 29173-087, Serra/ES, Brazil
lucassoares@hotmail.com, diego.lobao@gmail.com, pintoluizalberto@gmail.com

Abstract. Rotating electrical machines are essential components of modern production systems. Due to their structural characteristics, as, small gaps between fixed and moving parts, and by operating at high rotational speeds, a local incipient failure can spread out through the entire equipment, leading to system and production shutdown. In view of this, an efficient maintenance strategy becomes necessary to ensure the availability and safety of equipment, facilities, and operators. This work presents the development stages of a system to detect and diagnose failures in rotating equipment, through vibration signals analysis from the data set Mafaulda. For failure detection and diagnosis, a fusion of descriptors in both time and time/frequency domains is used. In the classification stage, the following Machine Learning algorithms are applied: Support Vector Machine (SVM), Artificial Neural Networks (ANN) and Random Forest (RF). The obtained results, considering the accuracy (98,63%) with RF, in diagnosing failures such as shaft misalignments, structural unbalances, as well as bearings failures, indicate that the use of intelligent systems in detecting and diagnosing failures in rotating machines, in fact, improves the availability and reliability of production systems, reducing untimely stops for corrective maintenance.

Keywords: failure detection, rotating electrical machines, vibration signal analysis, pattern recognition.

1 Introdução

As máquinas elétricas rotativas, em particular os motores elétricos, são componentes importantes nos sistemas de produção. A garantia do bom funcionamento desses equipamentos pode assegurar a continuidade operacional dos processos, a segurança dos operadores, bem como a qualidade dos produtos. Considerando suas características construtivas e as condições rígidas de operação a que estão sujeitas, a possibilidade de ocorrência de falhas torna-se inerente ao funcionamento das máquinas rotativas.

De forma geral, falhas em máquinas elétricas rotativas se manifestam ainda em estágio incipiente, afetando o seu desempenho antes mesmo de sua consolidação, o que via de regra provoca a interrupção do processo produtivo. Um motor em estágio de falha incipiente, pode apresentar vários indícios de funcionamento anormal, tais como, alterações nos sinais associados às vibrações mecânicas e variações na temperatura de operação. Dessa forma, o desenvolvimento de sistemas de diagnóstico de falhas em máquinas rotativas, através da análise dos sinais emitidos pelo processo, com a utilização de técnicas de *Machine Learning* pode identificar falhas ainda em estágio de evolução, permitindo intervenções corretivas programadas antes que as mesmas evoluam para estágios que provoquem danos nos equipamentos, comprometam a segurança de operadores e a interrupção da produção.

Esse trabalho propõe o desenvolvimento de um sistema para diagnóstico de falhas em máquinas elétricas rotativas, através da análise dos sinais de vibração disponíveis no conjunto de dados Mafaulda. Para a identificação das falhas, serão utilizados os algoritmos *Support Vector Machine (SVM)*, Redes Neurais Artificiais Perceptron Multicamadas (RNA-MLP) e Floresta Aleatória (FA). Para a representação das falhas (desalinhamento de eixo, desbalanceamento estrutural e diversas falhas nas esferas dos rolamentos), serão utilizados descritores estatísticos extraídos dos sinais no domínio do tempo e no domínio tempo/escala com a utilização da transformada *wavelet*.

O restante desse trabalho está organizado nas seguintes seções: a Seção 2 contém uma breve revisão bibliográfica sobre a detecção de falhas em máquinas elétricas rotativas através da análise de sinais de vibração com a utilização da transformada *wavelet*; a Seção 3 traz o referencial teórico com uma descrição sucinta dos algoritmos de classificação; a Seção 4 descreve a metodologia que orientou a realização da pesquisa; a Seção 5 apresenta os resultados obtidos, e a Seção 6 traz as conclusões derivadas da realização do trabalho.

2 Revisão Bibliográfica

Diversos trabalhos sobre detecção de falhas em máquinas elétricas rotativas têm sido publicados envolvendo a análise de sinais de vibração com a utilização da transformada *wavelet*. Em [1], é apresentado um estudo sobre o diagnóstico de falhas em rolamentos utilizando redes neurais artificiais e *SVMs*. Os experimentos foram realizados em uma bancada de testes, e a partir dos coeficientes obtidos com a aplicação da transformada *wavelet* foram extraídos nove descritores estatísticos, sendo estes o valor médio, valor RMS, valor de pico, variância, desvio padrão, assimetria, curtose, fator de crista e velocidade de rotação do eixo do motor. A função *wavelet* utilizada foi a Morlet, selecionada, por ter apresentado melhor desempenho, entre um grupo de funções *wavelet* testadas, nos critérios da Relação entre a Máxima Energia e a Mínima Entropia (*EER -Energy-to-Entropy Ratio*) e a Informação Máxima (*MI - Maximum Information*), que quantifica o percentual de extração de informação do sinal vibracional. Os autores reportam resultados na classificação da ordem de 94% para as redes neurais e 96% para o *SVM*.

Os autores em [2] realizaram um estudo para a detecção de falhas em alternadores a partir da análise de sinais de vibração com a aplicação da transformada *wavelet* discreta e Máquinas de Vetores de Suporte de Mínimos Quadrados (*LS-SVM - Least Square Support Vector Machine*). Para a aquisição dos sinais, foi montado um conjunto experimental composto por um motor elétrico, um inversor de frequência e um alternador. Para o processamento dos sinais, foi utilizado o filtro *wavelet* Db1 e quatro níveis de decomposição. A partir dos coeficientes da *wavelet* discreta, foram extraídos vinte e cinco descritores estatísticos explicitados por meios de suas equações características, que foram aplicados na etapa de classificação com o *LS-SVM*, obtendo a acurácia de 90,48%.

Uma investigação sobre a aplicação da transformada *wavelet* no diagnóstico de falhas em freios de veículos usando sinais de vibração está apresentada em [3]. Para a extração de características dos sinais, os autores utilizaram as *wavelets* Haar, Daubechies (db2 – db10), Symlet (sym2 – sym8), Coiflet (coif1 – coif5), Reverse Bi-orthogonal (rbio1.1 a 6.8), Biorthogonal (bior 1.1 a 6.8), Meyer e Fejér-Korovkin (fk4, fk6, fk8, fk14, fk18, fk22), em todos os casos os sinais foram decompostos em seis níveis de resolução. A partir dos coeficientes *wavelets*, foram extraídos os descritores estatísticos erro padrão, desvio padrão, média, mediana, curtose, assimetria, moda, coeficiente de variância, amplitude, sumarização, valor mínimo e valor máximo. Na etapa de classificação, os doze descritores estatísticos foram utilizados como entrada dos algoritmos de classificação *Best First Tree (BFT)*, *Hoeffding Tree (HT)*, *SVM* e *Neural Networks (NN)*. A acurácia alcançada pelos classificadores foi de 99,27% para o *BFT*, 99,45% para o *HT*, 94,92% para o *SVM* e 94,34% para a *NN*.

Em [4], foi proposta a utilização da transformada *wavelet* discreta para classificação de condições de falha em rolamentos, problema que foi composto por quatro classes, sendo a condição normal e as três condições de falhas, falha na pista interna, falha na pista externa e falha nas esferas. Para a aquisição dos sinais, foi utilizada uma bancada de testes elaborada pelos autores, e para a extração dos descritores, os autores utilizaram o filtro *wavelet* db4, tendo sido os sinais decompostos em quatro níveis de resolução. A partir dos coeficientes de aproximação e detalhe, em todos os níveis foram extraídos os descritores estatísticos média, variância, curtose, Valor RMS, Valor de pico a pico, fator de forma, fator de crista e fator de impulso que foram utilizados como entrada para o modelo obtido por meio do algoritmo *Fuzzy C-means clustering (FCM)*. O método proposto apresentou desempenho de 100% de acurácia na identificação da falhas.

Em recente trabalho, [5] propuseram uma metodologia de diagnóstico de falhas em caixas de engrenagens planetária que, segundo os autores, são muito utilizadas em turbinas eólicas. A análise foi realizada a partir de sinais de vibração obtidos em um simulador experimental composto por computador, encoder, cartão para aquisição de dados, motor de indução, uma caixa de engrenagem planetária, sistema de freios e controlador. O conjunto de falhas investigadas estava relacionado as condições dos dentes das engrenagens, e consistiram de identificação de dentes removidos por inteiro, dentes trincados, dentes com desgastes excessivos e dentes parcialmente quebrados. Para a identificação das falhas, foi proposta uma combinação da transformada *wavelet* discreta (*DWT*) com uma rede neural convolucional (*CNN*). Não é mencionado no trabalho qual o filtro *wavelet* utilizado para a decomposição dos sinais, mas é informado que os sinais foram decompostos em seis níveis de resolução. Os descritores utilizados foram os próprios coeficientes extraídos com a *DWT*, tendo estes constituído uma matriz de dimensões 64 por 64 de entrada para a Rede Neural Convolucional (*Convolutional Neural Network - CNN*). O método proposto obteve uma acurácia de 99,3%, o que, segundo os autores, mostra-se uma solução viável para o problema investigado.

3 Referencial Teórico

Nessa seção são apresentados os principais aspectos relacionados aos algoritmos utilizados para a construção dos modelos de classificação, *SVM*, *RNA-MLP* e *FA*. Além disso, é feita uma breve descrição da Transformada *Wavelet*, aqui utilizada para extração de coeficientes no domínio tempo/escala.

3.1 Support Vector Machine

São classificadores lineares binários não-probabilísticos que se baseiam na teoria de aprendizado estatístico [6]. Para a classificação, o algoritmo busca um hiperplano de separação entre duas classes, de forma a maximizar a distância entre dois objetos mais próximos. Em problemas não-lineares, o SVM utiliza funções *kernel*, as quais, realizam a transformação do espaço dimensional dos dados não linearmente separáveis para uma dimensão superior onde pode ser encontrado um limite de decisão linear. A função *kernel* utilizada nesse trabalho foi a linear. Por se tratar de um classificador binário, problemas de classificação que envolvam mais de duas classes requerem a aplicação de métodos multiclases. Como decisão de projeto, nesse trabalho foi utilizado o método multiclasse *one-vs-one*. Nessa abordagem, dadas n classes são gerados $n(n - 1)/2$ classificadores binários, sendo cada um deles responsável por determinar apenas um par de classes. O resultado final é definido por votação, sendo a classe mais votada atribuída à amostra.

3.2 Redes Neurais Artificiais - Perceptron Multicamadas

As redes neurais artificiais do tipo Perceptron Multicamadas, são constituídas por uma camada de entrada, uma ou mais camadas intermediárias de neurônios e uma camada de saída. Nessa arquitetura, todos os neurônios de todas as camadas são conectados a todos os neurônios das camadas vizinhas. O fluxo de informações se inicia na camada de entrada e, na sequência, percorre as camadas intermediárias até alcançar a camada de saída [7]. Para o ajuste dos pesos é utilizado o algoritmo *backpropagation*, que consiste em dois estágios, o *forward* e o *backward*. No primeiro estágio, *forward*, cada neurônio da primeira camada recebe a amostra e aplica a função de ativação. A saída dessa camada é utilizada como entrada da camada seguinte, assim sucessivamente até que seja obtida a saída da rede. No segundo estágio, *backward*, a saída da rede é comparada com o valor desejado, calculando assim o valor do erro. Os valores dos pesos sinápticos e dos limiares dos neurônios são ajustados no percurso entre a camada de saída até a primeira camada intermediária. Existem várias versões do algoritmo *backpropagation*, nessa pesquisa foi utilizado o *gradiente descendente*. A rede neural utilizada nos testes contém duas camadas ocultas, sendo a primeira com oitenta neurônios e a segunda com vinte, o número de épocas de treinamento foi limitado a cinquenta.

3.3 Floresta Aleatória

A Floresta Aleatória é uma coleção de Árvores de Decisão [8]. A Árvore de Decisão é um classificador estruturado na forma de um grafo com nós de decisão e arcos, aos quais estão associadas as regras que serão aplicadas na classificação [9]. A classificação de amostras desconhecidas resulta do conjunto de decisões, segundo critérios específicos, que são tomadas ao se percorrer à árvore. Critérios de decisão que podem ser utilizados são, por exemplo, a Entropia e o Índice *Gini*. De forma geral, a Árvore de Decisão apresenta bons desempenhos em tarefas de classificação. Contudo, para problemas que envolvam grandes conjuntos de dados e alta variância a Floresta Aleatória pode ser mais adequada. Uma das formas para implementar a Floresta Aleatória, é a utilização do *bagging*. O *bagging* particiona o conjunto de treino em diversos subconjuntos. Para cada subconjunto, descritores são selecionados e um modelo é treinado formando diversas árvores cujos resultados são combinados. Ao estimar uma entrada, cada árvore irá classificar o subconjunto de forma independente, sendo que a decisão a respeito da classe que a amostra desconhecida pertence será resultado de um processo de votação, e a classe atribuída será aquela com maior número de votos. Nesta pesquisa foi utilizada uma coleção de 100 árvores.

3.4 Transformada Wavelet

A Transformada *Wavelet* (TW) é uma ferramenta matemática eficiente para processamento de sinais, notadamente quando aplicada a sinais não-estacionários. Uma das vantagens de sua utilização é a possibilidade de, ao mesmo tempo, analisar um trecho específico, ou um intervalo do sinal, retendo as informações espectrais importantes e não-visíveis no domínio original, característica que pode ser vantajosa para aplicações de detecção de falhas a partir de sinais de vibração [10].

A versão discreta da Transformada *Wavelet* (TWD) pode ser obtida de forma computacionalmente eficiente através do uso de bancos de filtros digitais passa-altas e passa-baixas. A Figura 1 apresenta o esquema dos bancos de filtros de decomposição para cálculo da TWD. Nesse exemplo, foi considerado três níveis de resolução para a decomposição do sinal de entrada $f(x)$.

A estrutura do banco de filtros de decomposição consiste de um par de filtros, sendo um passa-baixas (h_0) e

um passa-altas (h_1), seguidos por operações de subamostragem. As saídas subamostradas dos filtros passa-baixas e passa-altas são denominadas coeficientes de aproximação e detalhe, respectivamente. As operações de filtragem/subamostragem podem ser reaplicadas, recursivamente, aos coeficientes de aproximação até o número de níveis de resolução especificado pelo analista. Os filtros h_0 e h_1 são de comprimento finito e, portanto, cada coeficiente de aproximação e detalhe corresponde a um trecho do sinal original. Como já anteriormente destacado, esta característica de localização espacial é uma das principais vantagens da transformada *wavelet* sobre a transformada de Fourier.

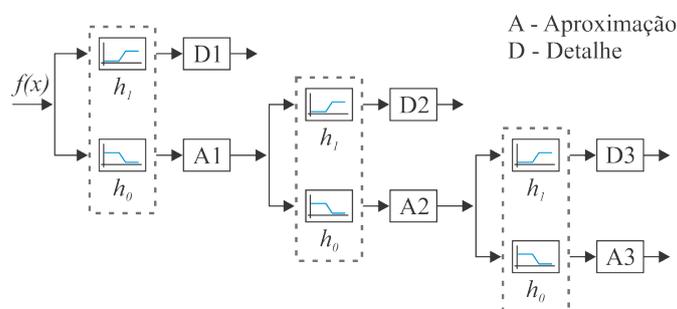


Figura 1. Decomposição do sinal $f(x)$ com a utilização de bancos de filtros passa-baixas e passa-altas.

4 Metodologia

Esta seção apresenta as etapas executadas para a realização dos experimentos, bem como o conjunto de dados utilizado. São descritas as etapas de extração de características, pré-processamento e treinamento dos classificadores.

4.1 O Conjunto de Dados Mafaulda

Os experimentos foram realizados utilizando o conjunto de dados colhido na bancada experimental *Machinery Fault Database (Mafaulda)* (Figura 2), de propriedade do *Signals, Multimedia, and Telecommunications Laboratory - COPPE/UFRJ*, que pode ser obtido livremente em <http://www02.smt.ufrj.br/~offshore/mfs/index.html#TOC1>. O conjunto de dados é constituído por 1951 amostras de sinais de vibração, distribuídos entre cinco classes, para análise e diagnóstico das falhas conforme apresentado na Tabela 1. A bancada é composta por um motor CC de 0,25 CV, e a faixa de velocidade utilizada nos testes variou de 700 a 3600 RPM. Para aquisição dos sinais de vibração foram utilizados sensores do tipo acelerômetro fixados sobre os mancais do equipamento, configurados para realizar medidas nas direções radiais e axiais. A coleta dos dados foi realizada com uma taxa de amostragem de 50 kHz durante 5 segundos, totalizando 250 mil pontos para cada amostragem. Maiores detalhes sobre a bancada experimental podem ser encontradas no trabalho de [11].

Tabela 1. Número de amostras por classe do conjunto de dados *Mafaulda*.

Classe	Condição de operação	Nº de amostras
<i>C1</i>	Normal	49
<i>C2</i>	Desalinhamento	498
<i>C3</i>	Desbalanceamento	333
<i>C4</i>	Falha no mancal 2	513
<i>C5</i>	Falha no mancal 1	558
<i>Total</i>		<i>1951</i>

A Figura 2 ilustra a bancada experimental e a posição de instalação dos acelerômetros. Os pontos de coleta dos sinais de vibração estão localizados nos mancais 1 e 2 e são representados por 1A, 1H e 1V referentes ao mancal 1, e os pontos 2A, 2H e 2V referentes ao mancal 2. Os sensores radiais são identificados como vertical (V) e horizontal (H), e permitem identificar falhas geradas por forças no sentido perpendicular ao eixo central do

equipamento. As medições no sentido axial (A) permitem identificar vibrações por movimentos paralelos ao eixo [12].

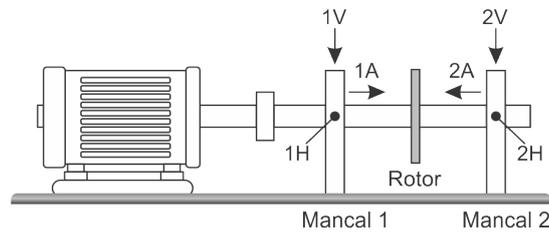


Figura 2. Bancada experimental *Mafaulda*.

4.2 Extração de características

Domínio do Tempo: na ocorrência de uma falha, as estruturas mecânicas rígidas no entorno do equipamento são afetadas produzindo sinais de vibração. De acordo com [13], [14] e [15], o comportamento da falha representado pelo sinal de vibração pode ser descrito por parâmetros estatísticos tais como, o valor médio (X_m), a raiz quadrada média (X_{rms}), o desvio padrão (X_{std}), entre outros. Tais atributos refletem variações na intensidade de uma falha, porém, para falhas em estágios iniciais, esses parâmetros não são eficientes para detecção. Para compensar essa baixa sensibilidade, outros parâmetros estatísticos são utilizados. De acordo com os trabalhos realizados por [16], [13] e [15], a curtose ($X_{kurtosis}$) e o fator de crista (X_{crest}) são bons indicadores de falhas incipientes, dessa forma, serão utilizados como descritores nesse trabalho.

A Tabela 2 apresenta a formulação matemática dos parâmetros estatísticos que foram utilizados como descritores dos sinais no domínio do tempo. Para cada amostra do sinal, obtida por cada um dos seis sensores, três parâmetros foram extraídos, constituindo assim amostras com dezoito descritores.

Tabela 2. Parâmetros estatísticos extraídos do sinal no domínio do tempo [17].

Raiz quadrada média	Curtose	Fator de crista
$X_{rms} = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$	$X_{kurtosis} = \frac{\sum_{n=1}^N (x(n) - X_m)^4}{(N-1)X_{std}^4}$	$X_{crest} = \frac{\max x(n) }{X_{rms}}$

A Figura 3 apresenta o comportamento dos sinais de vibração capturados pelo sensor 1V para cada uma das condições de operação (operação normal e as três condições de falhas), no período de 0,5 segundos numa velocidade próxima de 60 Hz. Pode-se notar que as diferentes condições de operação são refletidas nas diferenças entre as magnitudes em cada caso. Dessa forma, descritores baseados em parâmetros estatísticos no domínio do tempo podem representar diferentes padrões de comportamentos para cada natureza de falha.

Domínio tempo/escala: a extração de descritores no domínio tempo/escala, foi realizada com a utilização da transformada *wavelet*. Para isso, foram realizados testes utilizando as funções *wavelet* das famílias *coiflet*, *daubechies* e *symlet*. Para cada função *wavelet*, definiu-se o uso da quantidade máxima de níveis de decomposição do sinal, em seguida, para cada nível de decomposição, foram extraídos descritores baseados nos mesmos parâmetros estatísticos definidos para a abordagem no domínio do tempo, ou seja, a raiz quadrada média, a curtose e o fator de crista. A Tabela 3 apresenta as famílias *wavelet* utilizadas, o número máximo de níveis de decomposição dos sinais em cada uma delas, bem como a quantidade de descritores.

4.3 Treinamento do Classificador

Para a modelagem, o conjunto de dados foi particionado em treino e teste, com 70% e 30% das amostras, respectivamente. Os modelos foram obtidos utilizando os algoritmos *SVM*, *RNA-MLP* e *FA*, e foram treinados utilizando a validação cruzada com 10 partições. Como métrica de avaliação de desempenho foi utilizada a acurácia. Para evitar que descritores com maiores valores absolutos fossem enfatizados, os dados foram normalizados no intervalo de zero a um. Todos os testes foram realizados no Matlab®[®], R2019a.

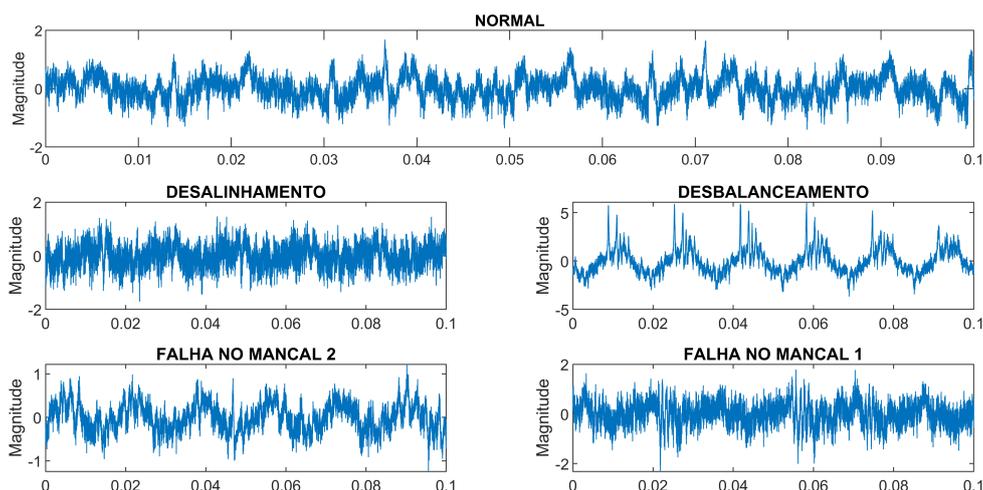


Figura 3. Sinais de vibração no domínio do tempo para cada condição de operação.

Tabela 3. Famílias *Wavelet* com número máximo de níveis de decomposição e a quantidade de descritores.

Função wavelet	Níveis de decomposição	Nº descritores
<i>coif2</i>	14	270
<i>coif5</i>	13	252
<i>db4</i>	15	288
<i>db10</i>	13	252
<i>sym2</i>	16	306
<i>sym10</i>	13	252

5 Resultados

A Tabela 4 apresenta a acurácia obtida nas etapas de testes utilizando os descritores baseados na decomposição *wavelet* de cada família, e através dos descritores baseados no domínio do tempo (DT).

Tabela 4. Resultados de acurácia utilizando descritores da decomposição *Wavelet* e dados estatísticos no domínio do tempo.

Classificadores	<i>coif2</i>	<i>coif5</i>	<i>db4</i>	<i>db10</i>	<i>sym2</i>	<i>sym10</i>	DT
<i>SVM</i>	80,34	70,09	77,78	91,45	76,41	76,58	47,01
<i>RNA-MLP</i>	90,60	91,62	90,77	87,18	90,09	91,45	65,13
<i>FA</i>	98,29	92,99	96,75	98,63	94,53	97,44	72,48

Conforme os resultados apresentados na Tabela 4, o modelo baseado em FA obteve desempenho superior ao *SVM* e a *RNA-MLP* em todos os testes. O melhor resultado foi obtido utilizando a decomposição *wavelet* da família *Daubechies* (*db10*) com 98,63% de acurácia. Pode-se notar também que a FA no DT, obteve desempenho inferior (72,48%), em comparação aos resultados obtidos com a decomposição *wavelet*, ou seja, para qualquer filtro baseado na decomposição *wavelet*, os resultados foram superiores a 92,99%. O melhor resultado para o modelo *SVM* foi obtido com a função *wavelet* *db10*, com 91,45% de acurácia, já o classificador *RNA-MLP* obteve seu melhor desempenho utilizando a função *wavelet* *coif5* com 91,62% de acurácia.

A utilização de somente três descritores estatísticos no domínio do tempo (valor rms, curtose e fator de crista), demonstra-se insuficiente para modelar adequadamente as falhas ocorridas no equipamento. Porém, os mesmos parâmetros estatísticos, quando extraídos em cada nível de decomposição das diferentes funções *wavelet*, podem descrever com sucesso o comportamento do processo quando da ocorrência das falhas, o que resulta no melhor desempenho dos classificadores.

6 Conclusão

Os resultados obtidos demonstram que, a utilização da transformada *wavelet* para a decomposição de sinais de vibração, pode, de fato, trazer informações relevantes relacionadas as falhas, que no domínio do tempo não são utilizadas para a obtenção dos modelos de classificação. A fusão de descritores obtidos com a utilização de parâmetros estatísticos, em diferentes níveis de decomposição da transformada *wavelet*, melhora sensivelmente, a separabilidade entre as classes, e a capacidade de predição dos classificadores. Os resultados mostram também que, a utilização dos descritores estatísticos, valor rms, curtose e fator de crista, no domínio do tempo, não conseguem modelar com precisão o comportamento das falhas estudadas nesse trabalho. Contudo, esses mesmos descritores, quando extraídos nos diferentes níveis de decomposição *wavelet* aumentaram de forma significativa a acurácia dos modelos de classificação.

As amostras investigadas possuem boas características de separabilidade, o que facilita o desempenho dos algoritmos de classificação. Em geral, o melhor desempenho no testes foi obtido com o classificador FA utilizando a função *wavelet db10* com 98,63% de acurácia, o que demonstra a possibilidade da elaboração de diagnósticos precisos e confiáveis.

Os resultados obtidos nesse trabalho confirmam a tendência da utilização crescente de técnicas de reconhecimento de padrões em sistemas de diagnóstico automático de falhas na indústria. No contexto atual, a utilização das informações extraídas dos sensores dos equipamentos, combinadas com técnicas de aprendizagem de máquinas, formam uma ferramenta poderosa no diagnóstico de falhas. A utilização dessas ferramentas estão alinhadas ao conceito de *Prognostics and Health Management*, no qual é possível estimar a ocorrência de uma falha, programando intervenções quando estas ainda estão em estágios iniciais, reduzindo assim os custos de manutenção.

Referências

- [1] Agrawal, P. & Jayaswal, P., 2020. Diagnosis and classifications of bearing faults using artificial neural network and support vector machine. *Journal of The Institution of Engineers (India): Series C*, vol. 101, n. 1, pp. 61–72.
- [2] Abad, M. R. A. A., Moosavian, A., & Khazaei, M., 2016. Wavelet transform and least square support vector machine for mechanical fault detection of an alternator using vibration signal. *Journal of Low Frequency Noise, Vibration and Active Control*, vol. 35, n. 1, pp. 52–63.
- [3] Alamelu Manghai, T. & Jegadeeshwaran, R., 2019. Vibration based brake health monitoring using wavelet features: A machine learning approach. *Journal of vibration and control*, vol. 25, n. 18, pp. 2534–2550.
- [4] Anbu, S., Thangavelu, A., & Ashok, S. D., 2019. Fuzzy c-means based clustering and rule formation approach for classification of bearing faults using discrete wavelet transform. *Computation*, vol. 7, n. 4, pp. 54.
- [5] Chen, R., Huang, X., Yang, L., Xu, X., Zhang, X., & Zhang, Y., 2019. Intelligent fault diagnosis method of planetary gearboxes based on convolution neural network and discrete wavelet transform. *Computers in Industry*, vol. 106, pp. 48–59.
- [6] Cortes, C. & Vapnik, V., 1995. Support-vector networks. *Machine learning*, vol. 20, n. 3, pp. 273–297.
- [7] Haykin, S., 2010. *Neural Networks and Learning Machines*, 3ed. Pearson Education India.
- [8] Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A., 1984. *Classification and Regression Trees*. CRC press.
- [9] Fürnkranz, J., Gamberger, D., & Lavrač, N., 2012. *Foundations of rule learning*. Springer Science & Business Media.
- [10] Al-Badour, F., Sunar, M., & Cheded, L., 2011. Vibration analysis of rotating machinery using time-frequency analysis and wavelet techniques. *Mechanical Systems and Signal Processing*, vol. 25, n. 6, pp. 2083–2101.
- [11] Lopez, R., 2014. Classificação automática de defeitos em máquinas rotativas. *Projeto de graduação, Universidade Federal do Rio de Janeiro*.
- [12] Mobley, R. K., 1999. *Vibration fundamentals*. Elsevier.
- [13] Rauber, T. W., de Assis Boldt, F., & Varejão, F. M., 2015. Heterogeneous feature models and feature selection applied to bearing fault diagnosis. *IEEE Transactions on Industrial Electronics*, vol. 62, n. 1, pp. 637–646.
- [14] Nayana, B. R. & Geethanjali, P., 2017. Analysis of statistical time-domain features effectiveness in identification of bearing faults from vibration signal. *IEEE Sensors Journal*, vol. 17, n. 17, pp. 5618–5625.
- [15] Tahir, M. M., Khan, A. Q., Iqbal, N., Hussain, A., & Badshah, S., 2017. Enhancing fault classification accuracy of ball bearing using central tendency based time domain features. *IEEE Access*, vol. 5, pp. 72–83.
- [16] Ali, J. B., Fnaiech, N., Saidi, L., Chebel-Morello, B., & Fnaiech, F., 2015. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Applied Acoustics*, vol. 89, pp. 16–27.
- [17] Lei, Y., 2016. *Intelligent fault diagnosis and remaining useful life prediction of rotating machinery*. Butterworth-Heinemann.