

Uma Análise Comparativa do Desempenho de Algoritmos de Classificação no Diagnóstico de Falhas em Rolamentos de Motores Elétricos a Partir de Sinais de Vibração

Rodrigo Cesar Campos* Gizele Poltronieri do Nascimento*
Gabriel Tozatto Zago* Luiz Alberto Pinto*

* Instituto Federal do Espírito Santo, Serra, ES, Brasil (e-mail:
rodrigoccampos@gmail.com; gizelepolt@gmail.com;
gabriel.zago@ifes.edu.br; pintoluizalberto@gmail.com).

Abstract: Electric motors are the most common equipment in industrial plants, and bearings are the most vulnerable components to failure. Considering the importance of electric motors operating in good conditions to maintain the continuity of the production process in industrial plants, this work investigates and compares the performance of several classification architectures when applied to the diagnosis of bearing failures. To build the models 13 statistical descriptors were extracted from the vibration signals available in the Paderborn data set. The models were built in the time domain and time-scale domain using the wavelet transform, and the k-Nearest Neighbour (k-NN), Support Vector Machine (SVM) and Decision Tree (DA) algorithms were applied. The performances of the models were evaluated using the metrics of accuracy, precision, sensitivity, specificity, and F1-score. The average result obtained in all classifier configurations was around 98%.

Resumo: Motores elétricos são os equipamentos de maior ocorrência em plantas industriais, e os rolamentos são os componentes mais vulneráveis à falhas. Considerando a importância de os motores elétricos operarem em boas condições de conservação para a manutenção da continuidade do processo de produção dos parques industriais, esse trabalho investiga e compara o desempenho de diversas arquiteturas de classificação quando aplicadas ao diagnóstico de falhas em rolamentos. Para a construção dos modelos, 13 descritores estatísticos foram extraídos dos sinais de vibração disponíveis no conjunto de dados Paderborn. Os modelos foram construídos no domínio do tempo e no domínio tempo-escala com a utilização da transformada *wavelet*, e foram aplicados os algoritmos *k-Nearest Neighbour (k-NN)*, *Support Vector Machine (SVM)* e *Árvore de Decisão (AD)*. Os desempenhos dos modelos foram avaliados com a utilização das métricas de acurácia, precisão, sensibilidade, especificidade e *F1-score*. O resultado médios obtido em todas as configuração dos classificadores foi em torno de 98%.

Keywords: bearing; fault; wavelet transform; classification algorithms; statistical descriptors.

Palavras-chaves: rolamento; falhas; transformada *wavelet*; algoritmos de classificação; descritores estatísticos.

1. INTRODUÇÃO

No ramo industrial é indispensável obter alta disponibilidade e confiabilidade dos equipamentos para garantir a continuidade operacional das plantas de processos sem que ocorram paradas indesejadas ou emergenciais. Neste aspecto, a gestão de manutenção dos equipamentos tem um papel fundamental, e um bom plano de manutenção permite reduzir o número de paradas indesejadas e não programadas dos equipamentos, aumentando assim a disponibilidade, continuidade operacional, produtividade, qualidade do produto, redução de gastos com peças de reposição e aumento do tempo de vida útil dos equipamentos. Desta forma, o gerenciamento eficiente da manutenção é extremamente importante para o sucesso das indústrias.

Motores elétricos são equipamentos de fundamental importância para o bom funcionamento dos processos produtivos. A ocorrência de falhas nesses equipamentos pode ocasionar a parada de processos produtivos críticos. O diagnóstico precoce pode mitigar os efeitos das falhas sobre os equipamentos e processos, reduzindo os custos de manutenção e as perdas relacionadas aos tempos de paradas não programadas para a realização de intervenções corretivas.

Uma abordagem que tem sido amplamente utilizada nas indústrias modernas é o monitoramento contínuo das condições de operação dos motores com a utilização de sistemas inteligentes para detecção e diagnóstico de falhas. O princípio fundamental sobre o qual tais sistemas se baseiam, é que, de forma geral, do momento em que uma falha se manifesta (estágio de falha incipiente), até o momento em que ela se estabelece (falha consolidada),

diversos estágios são atingidos. Quanto mais cedo a condição anormal de funcionamento for diagnosticada, menores serão os custos de manutenção e as perdas de produção.

Para o monitoramento contínuo das condições de operação de motores elétricos, sensores são conectados ao processo para a medição de variáveis críticas, tais como, temperatura, vibração, corrente elétrica, pressão. As assinaturas de eventuais condições de funcionamento anormais são capturadas por sistemas de aquisição de dados e posteriormente utilizadas para a implementação de sistemas inteligentes de diagnóstico. Um modelo eficaz de diagnóstico de falha orientado a dados envolve três etapas básicas: (1) aquisição de dados do rolamento durante a operação, (2) extração de variáveis dos sinais para caracterizar assinaturas das falhas e (3) classificação de diferentes condições de operação do rolamento com base nas características utilizadas para a modelagem (Islam et al., 2016).

Devido as condições críticas de operação a que os motores elétricos são submetidos, operando, geralmente, em altas velocidades de rotação em ambientes sujeitos ao pó e em contato com outros materiais, os rolamentos são os componentes dos motores mais sujeitos a falhas de diversas naturezas. Métodos inteligentes de diagnóstico de falhas em rolamentos com base na análise de sinais têm sido amplamente aplicados nas indústrias. A utilização da Transformada *Wavelet* juntamente com algoritmos de reconhecimento de padrões para classificação das falhas a partir da análise de sinais de vibração tem sido uma abordagem aplicada com sucesso em diversas aplicações na manutenção industrial.

Nesse contexto, esse trabalho se propõe a investigar e comparar o desempenho de vários modelos de classificação no diagnóstico das falhas de rolamentos de motores elétricos através da análise de sinais de vibração. Os modelos a serem comparados serão construídos com a utilização de descritores estatísticos extraídos tanto no domínio do tempo, quanto no domínio tempo-escala. Para a transformação dos sinais originais do domínio do tempo para o domínio tempo-escala serão aplicados os filtros *wavelet* das famílias *Coiflet*, *Daubechies* e *Symlet*. Os classificadores serão implementados com a utilização dos algoritmos *k-Nearest Neighbour (k-NN)*, *Support Vector Machine (SVM)* e *Árvore de Decisão (AD)*. Para a realização dos experimentos será utilizado o conjunto de dados *Paderborn* (Lessmeier et al., 2016), que é constituído por sinais correspondentes à condição de funcionamento normal, bem como a diversas condições de falha.

No que segue, este artigo está organizado em seis seções: na Seção 2 são apresentados os trabalhos correlacionados com o presente tema mais recentemente publicados. A Seção 3 descreve, de forma breve, as ferramentas e algoritmos utilizados para a realização dos experimentos. A Seção 4 apresenta a metodologia que conduziu a realização da pesquisa. Os Resultados obtidos estão apresentados na Seção 5 e, finalmente, a Conclusão e discussão final são realizadas na Seção 6.

2. REVISÃO DA BIBLIOGRAFIA

Falhas em motores elétricos têm recebido a atenção dos meios acadêmicos e industriais, pois, ao serem detectadas

de forma precoce, paradas não programadas para manutenções corretivas são evitadas, bem como interrupções na produção (Nishat Toma and Kim, 2020; Toma et al., 2020).

Diversas pesquisas envolvendo diagnósticos de falhas em rolamentos de motores elétricos com a utilização de sinais de vibração vem sendo desenvolvidas nos últimos anos. Segundo Toma et al. (2020), os sinais de vibração transportam informações importantes sobre as condições do estado de funcionamento dos rolamentos, sendo, por isso, comumente utilizados para a construção de modelos de diagnóstico e predição de falhas.

Pesquisas sobre diagnóstico inteligente de falhas em rolamentos de esferas aplicando Redes Neurais Artificiais (RNAs) e *Support Vector Machine (SVM)* foram apresentadas no trabalho de Kankar et al. (2011). Através da análise e extração de descritores de sinais de vibração, os autores investigaram diversas falhas nos rolamentos de esferas, tais como, defeitos nas pistas externa e interna, defeitos nos elementos rolantes e uma combinação de todos eles. Métodos estatísticos são utilizados para extração de descritores no domínio do tempo como a média, o desvio padrão, a assimetria, a amplitude, a curtose e o fator de crista. Técnicas de seleção de atributos utilizando algoritmos de aprendizado de máquinas foram utilizados para reduzir a dimensionalidade do conjunto. Apesar da baixa acurácia devido a pequena amostragem contida no conjunto de dados, 71,23% para o modelo utilizando RNA e 73,97% para o modelo utilizando SVM, os autores consideraram que os resultados da classificação se mostraram promissores e com grande potencial de aplicação em sistemas de diagnósticos inteligentes para prevenção de falhas.

Pesquisas que utilizaram métodos de similaridades foram realizadas por Ribeiro et al. (2017). A utilização do modelo de similaridade auxilia na geração de descritores para um classificador e pode ser utilizada também como um classificador independente. O modelo baseado em similaridade é um algoritmo não paramétrico, capaz de procurar pelo menor número de amostras representativas que sejam suficientes e eficazes para descrever cada classe. Os autores utilizam dados estatísticos no domínio do tempo e da frequência para extração dos descritores, e como classificador é utilizado um modelo baseado em Floresta Aleatória. Resultados experimentais utilizando os conjuntos de dados *Mafaulda* e *CWRU (Case Western Reserve University)* mostram o poder de generalização do modelo, no qual foi possível obter taxas de acerto acima de 96%. Em (Gongora et al., 2018), uma RNA embarcada é desenvolvida para detectar falhas no rolamento através do sinal da corrente elétrica. Em Eren et al. (2018) os autores apresentam redes neurais convolucionais (CNN) compactas capazes de classificar falhas em rolamentos através de sinais de vibração, utilizando conjuntos de dados públicos (como o CWRU) para validar o trabalho. Em Markiewicz et al. (2019) os autores apresentaram uma solução embarcada completa de baixo consumo para classificação de falhas utilizando redes *Long Short-Term Memory (LSTM)*.

Em Lu et al. (2020) os autores classificaram 7 tipos de falha, além do funcionamento normal em motores de indução. Para tal, utilizaram 8 motores, cada um em uma condição de falha ou funcionamento normal. Dados de vibração foram adquiridos a uma taxa de 20 kHz e três

testes de classificação foram realizados em um sistema microcontrolado. No primeiro teste, imagens 28 x 28 foram geradas a partir dos sinais e uma *CNN* com duas camadas convolucionais foi utilizada para a classificação. No segundo os autores usaram as mesmas imagens 28 x 28 e uma *CNN* com uma camada convolucional para classificação, e no terceiro teste geraram imagens 14 x 14 e as classificaram utilizando a *CNN* com duas camadas convolucionais. As acurácias alcançadas foram 100%, 97,5% e 94,13% para cada teste, respectivamente.

Os autores em Chen et al. (2020) compararam os desempenhos de duas redes neurais com diferentes *kernels* para extrair descritores de sinais de vibração de rolamentos de motores elétricos. Em uma etapa anterior a classificação, os sinais de vibração foram subamostrados a fim de reduzir a quantidade de variáveis. Uma *LSTM* foi utilizada para a classificação das faltas ocorridas no processos, tendo os autores relatado uma acurácia de 98,46%.

Os autores em Toma et al. (2020) propuseram uma abordagem híbrida baseada nos sinais de corrente do motor para diagnosticar falhas em motores elétricos. O método consistiu na extração de descritores estatísticos dos sinais de corrente e a posterior seleção de variáveis com a utilização de algoritmos genéticos. Os modelos de classificação foram construídos utilizando os algoritmos *k-NN*, Árvore de Decisão e Floresta Aleatória. Os resultados experimentais mostraram que os três classificadores alcançaram desempenho geral acima de 97%.

Em da Silva Barcelos et al. (2021) os autores utilizaram os sinais de corrente de um motor de indução trifásico para construir modelos de diagnóstico de falhas em rolamentos de motores. Para a extração dos descritores, os sinais foram transformados pela aplicação da transformada *wavelet* e pela aplicação da transformada de *Hilber-Huang*. Para o cálculo dos coeficientes *wavelet* os autores utilizaram o filtro *wavelet db20*, da família *Daubechies*, e para a decomposição dos sinais pela transformada de *Hilber-Huang* foi aplicado a técnica denominada *Empirical Mode Decomposition (EMD)*. Em ambos os domínios transformados, descritores foram extraídos com a utilização de funções estatísticas. Os modelos de classificação foram implementados com Redes Neurais Artificiais e *Support Vector Machine (SVM)*. Conforme informado pelos autores, o desempenho na classificação foi superior a 98% .

Em Apinantanapong and Nivesrangsan (2021) foi realizado um estudo de caso para classificar seis tipos de falhas em rolamentos do tipo 6006z. Para a implementação dos modelos, sinais de vibração foram coletados por meio de técnicas não intrusivas de detecção, que consistiu na instalação de acelerômetros em posições estratégicas da planta. Para a representação dos sinais de vibração foram utilizadas técnicas no domínio do tempo e frequência e, para a classificação foram utilizados os algoritmos *SVM*, *k-NN* e Redes Neurais Artificiais (RNA). O melhor resultado (98% de acurácia) foi obtido com o classificador implementado com RNA.

Como pode ser observado em alguns trabalhos relatados na revisão da literatura, embora técnicas baseadas em algoritmos de *Deep Learning* sejam o atual estado da arte na construção de modelos de diagnóstico de falhas em

rolamentos de motores, as abordagens tradicionais que utilizam os algoritmos *k-NN*, *SVM*, Árvore de Decisão, entre outros, podem ser opções viáveis para a construção desses modelos, por, de forma geral, apresentarem menor custo computacional de tempo e espaço de armazenamento, o que pode favorecer o desenvolvimento de sistemas embarcados de diagnósticos de falhas.

3. REFERENCIAL TEÓRICO

Nesta seção estão brevemente descritas as ferramentas utilizadas nos experimentos. A transformada *wavelet*, utilizada para a decomposição dos sinais de vibração, e os algoritmos *k-NN*, *SVM* e Árvore de Decisão utilizados para a construção dos classificadores.

3.1 *k-Nearest Neighbour - k-NN*

O *k-Nearest Neighbour* é um classificador não paramétrico que atribui à amostra desconhecida a mesma classe das *k* amostras mais próximas, segundo um critério de decisão. Sua simplicidade e eficácia fazem com que esse algoritmo seja amplamente utilizado em problemas de classificação (Fayed and Atiya, 2009). O princípio sobre o qual o *k-NN* se baseia, é de que amostras similares tendem a se concentrar em uma mesma região do espaço. Apesar de sua implementação ser simples, o *k-NN* não é muito robusto quando os dados apresentam *outliers* (Sugiyama, 2015). Para a classificação, o modelo necessita de uma regra de decisão, que geralmente consiste em atribuir à classe desconhecida a classe da maioria dos *k* vizinhos mais próximos. Além disso, um valor prévio de *k*, assim como a métrica de distância a ser utilizada, devem ser definidos previamente.

3.2 *Support Vector Machine - SVM*

Support Vector Machine são classificadores lineares binários não probabilísticos que se baseiam na teoria do aprendizado estatístico (Cortes and Vapnik, 1995). 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. Por se tratar de um classificador binário, problemas de classificação que envolvam mais de duas classes requerem a aplicação de métodos multiclases. Os métodos multiclases mais utilizados são *one-vs-one* e *one-vs-all*. No primeiro, também conhecido como todos-contra-todos, 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 pelo método de votação, sendo a classe mais votada atribuída à amostra. No segundo método, conhecido também como um-contra-todos, para um problema com *n* classes são gerados *n* classificadores binários, cada um especializado na sua classe. Essa técnica pode apresentar desvantagem quando ocorre um desbalanceamento considerável no conjunto de dados (Faceli et al., 2011).

3.3 Árvore de Decisão - AD

Algoritmos de aprendizagem baseados em árvore de decisão formam uma ampla família de métodos supervisionados não paramétricos que podem ser utilizados tanto para classificação quanto para regressão. Os algoritmos baseados em Árvore de Decisão, utilizam a estratégia dividir-para-conquistar, cujo processo de atribuição de uma classe é constituído por múltiplos estágios (Webb, 2003). Sua estrutura hierárquica em forma de árvore invertida o torna um classificador de simples implementação. As AD são constituídas por nós e ramos. As regras de decisão estão associadas aos nós, onde testes são realizados para a definição do percurso ao longo da árvore. Os ramos representam os possíveis caminhos a serem percorridos de acordo com a decisão tomada no nó precedente. Decisões sucessivas são tomadas até que um nó terminal seja alcançado, onde uma classe é atribuída à amostra desconhecida (Dougherty, 2013). A implementação da AD requer a definição prévia da profundidade da árvore e do critério de divisão.

3.4 Transformada Wavelet

A Transformada Wavelet (TW) (Mallat, 1989) é uma ferramenta matemática eficiente para processamento de sinais, notadamente quando aplicada a sinais não-estacionários, como é o caso dos sinais de vibração utilizados no presente trabalho. 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 do tempo, característica que pode ser vantajosa para aplicações de detecção de falhas (Al-Badour et al., 2011).

A Transformada Wavelet Contínua (TWC) (Strang and Nguyen, 1996), pode ser definida pela Equação (1):

$$TWC(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (1)$$

com $a \neq 0$, onde $x(t)$ é o sinal a ser analisado e a função $\psi(t)$ é denominada *wavelet*-mãe. A equação 1 pode ser interpretada como a convolução do sinal no domínio do tempo. A função $\psi(t - b/a)$ corresponde a *wavelet*-mãe dilatada/contráida pela escala a e transladada pelo fator b (Strang and Nguyen, 1996). O termo $1/\sqrt{|a|}$ é utilizado para assegurar que os valores da TWC em todas as escalas possam ser diretamente comparados, mantendo constante a energia (Strang and Nguyen, 1996).

A versão discreta da transformada pode ser diretamente obtida da TWC pela discretização dos parâmetros a e b , fazendo $a = a_0^j$ e $b = kb_0 a_0^j$, sendo j, k valores inteiros e $a_0 > 1, b_0 > 0$. Fazendo $a_0 = 2$ e $b_0 = 1$, obtém-se um caso particular de discretização denominado discretização diádica (Strang and Nguyen, 1996). Neste caso, pode-se obter a Transformada Wavelet Discreta de forma computacionalmente eficiente através do uso de bancos de filtros digitais passa-altas e passa-baixas. A Fig. 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 $f(x)$.

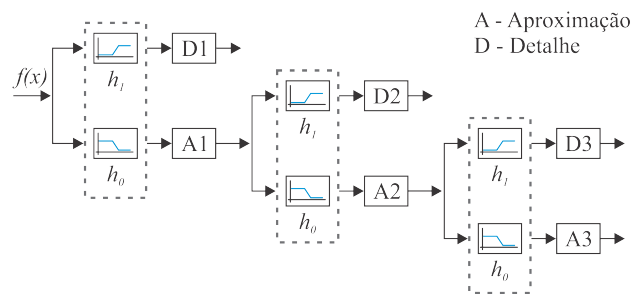


Figura 1. Decomposição do sinal $f(x)$ em análise multiresolução.

Fonte: Autoria própria.

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.

4. METODOLOGIA

Nesta seção estão descritas todas as etapas executadas na realização dos experimentos. São apresentados o conjunto de dados, as técnicas de pre-processamento utilizadas, bem como as etapas de treinamento e classificação. A Fig. 2 ilustra as etapas de modelagem do sistema de diagnóstico de falhas em rolamentos de motores elétricos




Figura 2. Etapas de classificação.

Fonte: Autoria própria.

4.1 Conjunto de Dados

Para a realização dos testes, na fase experimental foi utilizado o conjunto de dados Paderborn (Lessmeier et al., 2016), disponibilizado pela universidade de mesmo nome, com utilização livre para fins acadêmicos não comerciais, e que pode ser obtido em URL: groups.uni-paderborn.de/kat/BearingDataCenter. Na forma original, o conjunto Paderborn é constituído por sinais de vibração e corrente elétrica, que foram obtidos para diversas condições de operação de falha, reais e simuladas, além da condição de funcionamento normal.

Para a aquisição dos sinais, foi utilizada a bancada de teste mostrada na Fig. 3. A bancada é constituída por um motor síncrono de ímã permanente (1) de 425 W controlado por um inversor de frequência padrão com frequência de comutação de 16 kHz. Além do motor, a bancada é composta por, (2) um eixo de medição de torque, (3) um módulo de teste de rolamento, (4) um volante e (5) um motor de carga. Em Lessmeier et al. (2016) está apresentado o procedimento experimental detalhado para aquisição dos sinais.




Figura 3. Bancada de Teste Paderborn.
 Fonte: (Lessmeier et al., 2016).

Neste trabalho, por ser um caminho melhor consolidado na literatura, optou-se pela utilização dos sinais de vibração para o diagnóstico de falhas nos rolamentos.

Os sinais foram coletados para falhas geradas com os rolamentos em condições reais de funcionamento e também com rolamentos artificialmente danificados. Por representarem condições de funcionamento mais semelhantes aos dos motores que operam em processos industriais, para a realização deste trabalho, decidiu-se pela utilização dos sinais relacionados às falhas reais.

Além da condição de funcionamento normal, os modos de falha em condições reais de funcionamento disponíveis no conjunto de dados *Paderborn* são fadiga e deformação plástica com suas derivações, ocorridas em diferentes partes do rolamento e em diferentes extensões de falha. Assim, para formalização do problema de reconhecimento de padrões, o conjunto de dados utilizado para a construção dos modelos foi constituído por cinco classes de falha, além da classe correspondente ao funcionamento normal, conforme descritos na Tabela 1.

4.2 Pré-Processamento dos Sinais

Os sinais brutos, foram coletados na forma de vetores contendo 256.001 amostras. Esses sinais correspondem aos modos de funcionamento dos rolamentos, seja no modo normal ou de algum tipo de falha, conforme descrito na Tabela 1. Para constituição das classes, os sinais brutos foram particionados em 100 partes de 2560 amostras, que foram organizadas em uma matriz de 100 linhas com 2560 amostras, além da coluna correspondente ao *label* da classe. Dessa forma, as classes ficaram constituídas por 100 linhas de sinal e 2561 variáveis. A Tabela 1 apresenta as seis classes que constituíram o conjunto de dados utilizado para a modelagem, bem como os códigos correspondentes dos rolamentos no conjunto original. Amostras dos sinais das seis classes estão ilustradas na Fig. 4.

4.3 Extração de descritores estatísticos

Para fins de redução da quantidade de variáveis na fase de modelagem, a partir de cada uma das amostras disponíveis

Tabela 1. Classes de falhas que compõem o conjunto de dados além da classe normal

Classe	Categoria	Código
1	Normal (Healthy)	K001
2	Fadiga na pista externa	KA04
3	Deformação na pista externa	KA15
4	Fadiga na pista interna	KI04
5	Fadiga nas pistas externa e interna	KB23
6	Deformação nas pistas externa e interna	KB27

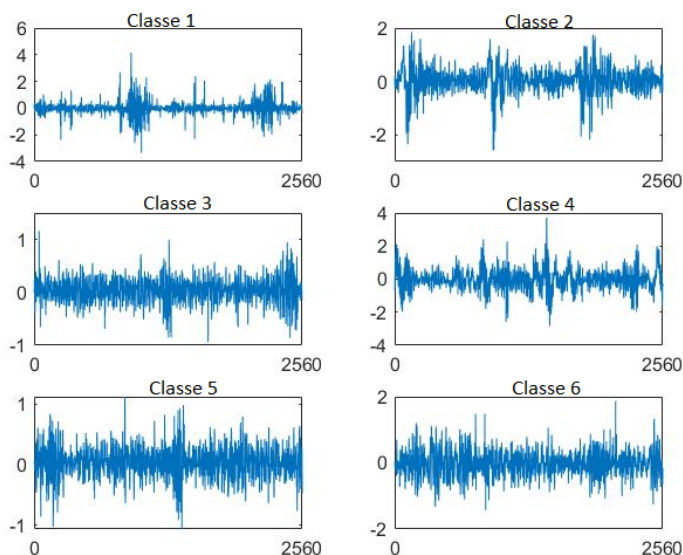


Figura 4. Amostras dos sinais das classes
 Fonte: Autoria própria.

na matriz que representa o problema, foram calculados os valores de 13 parâmetros estatísticos: o Valor médio (X_m), Valor de pico (X_{peak}), o Fator de folga ($X_{clearance}$), a Amplitude da raiz (X_{root}), a Curtose ($X_{kurtosis}$), o Fator de impulso ($X_{impulse}$), o Desvio padrão (X_{std}), a Assimetria ($X_{skewness}$), Fator de forma (X_{shape}), a Raiz quadrada média (X_{rms}), o Fator de crista (X_{crest}), o Valor de pico a pico ($X_{peak2peak}$) e a Raiz da soma do quadrado (X_{rssq}). De acordo com Lei (2016), sinais de vibração podem ser bem representados pelos parâmetros estatísticos utilizados nesse trabalho para fins de compressão e modelagem. A Tabela 2 apresenta a formulação matemática de cada um dos parâmetros estatísticos.

Com ampla utilização na literatura de classificação de falhas em máquinas rotativas (Guo et al., 2018; Tsyppkin, 2013), deve ser destacada a importância do valor da raiz quadrada média (X_{rms}) como descritor para análise dos sinais no domínio do tempo, que corresponde à medida do conteúdo de energia do sinal de vibração. Após a extração e cálculo dos parâmetros estatísticos dos sinais de vibração, o conjunto de dados para a modelagem ficou constituído por seis classes, cada uma contendo 100 amostras e 13 descritores.

Para representação dos sinais de vibração, os descritores estatísticos foram calculados, inicialmente, com os sinais no domínio do tempo e posteriormente com os sinais no domínio tempo-escala. Os sinais foram transformados para o domínio tempo-escala com a utilização dos filtros *wavelet* da família *Coiflet* (*coif5*), *Daubechies* (*db4*) e *Symlet* (*sym8*), que foram escolhidos por representarem

Tabela 2. Parâmetros estatísticos extraídos dos sinais e utilizados para a obtenção dos modelos

Parâmetro	Descrição Matemática
Valor médio	$X_m = \frac{\sum_{n=1}^N x(n)}{N}$
Valor de pico	$X_{peak} = \max x(n) $
Fator de folga	$X_{clearance} = \frac{X_{peak}}{X_{root}}$
Amplitude da raiz	$X_{root} = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2$
Curtose	$X_{kurtosis} = \frac{\sum_{n=1}^N (x(n) - X_m)^4}{(N-1)X_{std}^4}$
Fator de impulso	$X_{impulse} = \frac{X_{peak}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Desvio padrão	$X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - X_m)^2}{N-1}}$
Skewness	$X_{skewness} = \frac{\sum_{n=1}^N (x(n) - X_m)^3}{(N-1)X_{std}^3}$
Fator de forma	$X_{shape} = \frac{X_{rms}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Raiz quadrada média	$X_{rms} = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$
Fator de crista	$X_{crest} = \frac{X_{peak}}{X_{rms}}$
Valor de Pico a Pico	$X_{peak2peak} = 2 \cdot X_{peak}$
Raiz da Soma do Quadrado	$X_{rssq} = \sqrt{\sum_{n=1}^N x(n) ^2}$

as famílias *wavelet* com maior utilização na decomposição de sinais de vibração. Os sinais foram decompostos em todos os níveis de resolução possíveis, e para o cálculo dos descritores foram considerados tanto os coeficientes de aproximação como os de detalhe.

4.4 Treinamento e Classificação

Para a obtenção dos modelos, os conjuntos de dados, no domínio do tempo e no domínio tempo-escala, foram particionados em conjuntos de treino e teste, com 70% e 30% das amostras, respectivamente. Na fase de treino/validação foi utilizado o algoritmo *k-Fold Cross Validation* com cinco *folds*. Os modelos foram obtidos utilizando os algoritmos *k-NN*, *SVM* e *Árvore de Decisão*. Para o *k-NN* foram utilizados os valores de $k=1, 3, 5$ e 7 , e a distância euclidiana foi utilizada como métrica de distância. Para o *SVM* foi utilizado o método multiclasse *one-vs-one* e *kernel* do tipo linear, gaussiano e polinomial. Já na *Árvore de decisão* foram utilizadas ADs com número de ramos igual a 10, 20, 30, 40, 50 e 100, e como critério de divisão foi aplicado o índice Gini. Para avaliar o desempenho dos modelos foram utilizadas as métricas de acurácia, precisão, sensibilidade, especificidade e *F1-score*. Todos os testes foram realizados no Matlab, R2020a.

5. RESULTADOS

As tabelas 3, 4, 5 e 6 apresentam os melhores resultados dos testes no domínio do tempo e no domínio tempo-escala, com cada um dos algoritmos utilizados para a obtenção dos modelos de classificação. Em todos os testes os modelos foram obtidos com os 13 descritores calculados a partir dos parâmetros estatísticos dos sinais de vibração. Os resultados da classificação na fase de teste com os dados no domínio do tempo estão mostrados na Tabela 3. Por sua vez, as tabelas 4, 5 e 6 registram os melhores resultados

da classificação com os dados no domínio tempo-escala. Para os testes no domínio tempo-escala, os sinais foram decompostos em todos os níveis de resolução possíveis com as *wavelets* *coif5*, *db4* e *sym8*. Os resultados mostrados nas tabelas foram os melhores obtidos entre todos os testes envolvendo as diferentes configurações dos parâmetros dos algoritmos e os diferentes níveis de resolução em que os sinais de vibração foram decompostos.

Tabela 3. Classificação no domínio do Tempo

Classificador	Acc	Prec	Espc	Sensb	F1-Score
<i>k-NN - k=3</i>	0.9890	0.9889	0.9892	0.9889	0.9889
<i>SVM - Gau</i>	0.9945	0.9946	0.9786	0.9944	0.9944
AD - 50	0.9835	0.9842	0.9841	0.9833	0.9833

Tabela 4. Classificação utilizando a *wavelet* *Coif5* no melhor nível de resolução - Nível 3

Classificador	Acc	Prec	Espc	Sensb	F1-Score
<i>k-NN - k=5</i>	0.9890	0.9892	0.9892	0.9889	0.9889
<i>SVM - Gau</i>	0.9727	0.9724	0.9732	0.9722	0.9722
AD - 50	0.9945	0.9946	0.9946	0.9944	0.9944

Tabela 5. Classificação utilizando a *wavelet* *db4* no melhor nível de resolução - Nível 3

Classificador	Acc	Prec	Espc	Sensb	F1-Score
<i>k-NN - k=3</i>	0.9945	0.9946	0.9946	0.9944	0.9944
<i>SVM - Gau</i>	0.9835	0.9835	0.9838	0.9833	0.9833
AD - 50	0.9836	0.9833	0.9838	0.9833	0.9832

Tabela 6. Resultados da classificação utilizando a *Wavelet* *sym 8* - Nível 4

Classificador	Acc	Prec	Espc	Sensb	F1-Score
<i>k-NN - k=5</i>	0.9781	0.9785	0.9787	0.9778	0.9778
<i>SVM - Gau</i>	0.9784	0.9784	0.9792	0.9778	0.9778
AD - 20	0.9945	0.9946	0.9946	0.9944	0.9944

Comparando os desempenhos dos modelos na classificação das falhas com os sinais no domínio de tempo (Tabela 3), nota-se que os melhores resultados obtidos com os algoritmos *k-NN*, *SVM* e *Árvore de Decisão* são equivalentes. Entre os modelos construídos com o algoritmo *k-NN*, o obtido com três vizinhos (*k-NN - k=3*) apresentou melhor desempenho. Para os algoritmos *SVM* e *Árvore de Decisão* (AD), os melhores resultados foram apresentados pelos modelos com *kernel* gaussiano (*SVM - Gau*) e com 50 nós de divisão (AD - 50), respectivamente. Como pode ser notado, em quatro das cinco métricas de avaliação (Acc, Prec, Sensb e F1-Score) o *SVM - Gau* obteve o melhor desempenho no domínio do tempo.

Em relação aos resultados dos modelos com os sinais no domínio tempo-escala nota-se que, de forma geral, o desempenho dos modelos construídos com o filtro *wavelet* *db4*, considerando todas as métricas, apresentou resultados ligeiramente melhores que os demais filtros. Se forem analisados os desempenhos dos modelos com base na métrica de acurácia, pode-se dizer que os classificadores que utilizaram *Árvore de Decisão* apresentaram desempenhos superiores, tendo apresentado melhor valor de acurácia, entre todos os modelos, com os filtros *coif5* e *sym8*.

Outro resultado que merece ser destacado é o nível de resolução que resultou nos melhores modelos para cada filtro *wavelet*. Para os filtros *coif5* e *db4*, para todos os

algoritmos de classificação, os melhores modelos foram obtidos no terceiro nível de resolução. Para o filtro *sym8* não houve a prevalência de um nível de resolução no resultado dos modelos, tendo os melhores resultados sido obtidos nos níveis três e quatro. Os resultados da Tabela 6 referem-se aos modelos obtidos no quarto nível de resolução. Dessa forma, é possível afirmar que a faixa de frequência relacionada com o terceiro nível de resolução, melhor se ajusta às características dos sinais de vibração. Para o classificador *k-NN* os números de vizinhos que obtiveram melhores resultados foram $k = 3$ e $k = 5$. Para o *SVM* o *kernel* gaussiano, em todos os casos, resultou nos melhores modelos, e para a Árvore de Decisão, três entre os melhores resultados foram obtidos com 50 ramos.

De forma geral, todos os classificadores, independente do domínio da modelagem, apresentaram bom desempenho (valores das métricas em torno de 98 %). Em todas as configurações de teste os resultados se equivalem, não sendo observado superioridade dos modelos no domínio do tempo sobre os modelos no domínio *wavelet*, ou vice-versa. Quando utilizada a transformada *wavelet*, o terceiro nível de resolução demonstrou ser mais efetivo para a obtenção de bons modelos de classificação.

Os desempenhos semelhantes dos modelos nos domínios do tempo e tempo-escala podem ser atribuídos a assertividade do conjunto de descritores estatísticos utilizados para representar os sinais de vibração para efeito de modelagem. De fato, a utilização de descritores com boa capacidade de descrição do comportamento do fenômeno que se deseja modelar é tão, ou mais importante do que a escolha do algoritmo de classificação.

6. CONCLUSÃO

Neste artigo foi analisado o desempenho de algoritmos de classificação de falhas em rolamentos de motores elétricos através de sinais de vibração. Os modelos foram construídos nos domínios do tempo e tempo-escala, e em ambos os domínios foram utilizados descritores estatísticos extraídos dos sinais de vibração.

As tabelas 3, 4, 5 e 6 mostram que, independentemente do algoritmo de classificação utilizado para a construção do modelo, os resultados da classificação, nos domínios do tempo e tempo-escala são equivalentes. Considerando que a aplicação da transformada *wavelet* aumenta o custo computacional para o cálculo dos coeficientes, para o processo analisado nesse trabalho, não demonstra ser viável a utilização da transformada *wavelet*.

Os resultados da classificação de falhas de rolamento obtidos nesse trabalho são equivalentes aos melhores resultados obtidos em trabalhos correlatos, inclusive quando são utilizadas estratégias baseadas em *Deep Learning*, tais como *CNNs* e redes *LSTM*. Contudo, se for considerado que algoritmos de *Deep Learning*, de forma geral requerem maiores custos de computação, tanto relacionado a tempo de processamento como de memória de armazenamento, além de requererem, muitas vezes, conexão com a internet, pois o processamento geralmente é feito na nuvem, o que gera um problema de dependência de conectividade, o que pode reduzir a disponibilidade do sistema. Já os métodos convencionais de classificação baseados em algoritmos,

como os utilizados nesse trabalho (*k-NN*, *SVM* e Árvore de Decisão), são vantajosos para a implementação de sistemas de diagnóstico de falhas, pois, em tais sistemas o tempo de resposta é de fundamental importância para mitigar os efeitos da falta ainda em estágio incipiente. Além disso, para fins de desenvolvimento de sistemas embarcados, algoritmos que requerem menor custo computacional podem ser mais adequados do que algoritmos de *Deep Learning*.

AGRADECIMENTOS

Os autores agradecem a Cooperação CAPES/FAPES - PDPG, projeto TIC+TAC, pelo apoio financeiro (TO 133/2021, Processo Nº 2021-CFT5C).

REFERÊNCIAS

- Al-Badour, F., Sunar, M., and Cheded, L. (2011). Vibration analysis of rotating machinery using time-frequency analysis and wavelet techniques. *Mechanical Systems and Signal Processing*, 25(6), 2083–2101.
- Apinantanapong, N. and Nivesrangsan, P. (2021). Application of artificial neural networks to fault detection of rolling ball bearing. In *2021 6th International Conference on Business and Industrial Research (ICBIR)*, 147–152. IEEE.
- Chen, X., Zhang, B., and Gao, D. (2020). Bearing fault diagnosis base on multi-scale cnn and lstm model. *Journal of Intelligent Manufacturing*.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273–297.
- da Silva Barcelos, A., Mazzoni, F.M., and Cardoso, A.J.M. (2021). Análise de avarias em rolamentos, utilizando algoritmos de inteligência artificial. *Brazilian Journal of Development*, 7(3), 29080–29093.
- Dougherty, G. (2013). *Pattern Recognition and Classification: An Introduction*. Springer Publishing Company, Incorporated.
- Eren, L., Ince, T., and Kiranyaz, S. (2018). A generic intelligent bearing fault diagnosis system using compact adaptive 1d cnn classifier. *Journal of Signal Processing Systems*. doi:10.1007/s11265-018-1378-3.
- Faceli, K., Lorena, A.C., Gama, J., and de Carvalho, A.C. (2011). *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*, volume 1. LTC, Rio de Janeiro.
- Fayed, H.A. and Atiya, A.F. (2009). A novel template reduction approach for the *k*-nearest neighbor method. *IEEE Transactions on Neural Networks*, 20(5), 890–896.
- Gongora, W.S., Goedtel, A., Castoldi, M.F., Oliveira da Silva, S.A., and Da Silva, I.N. (2018). Embedded system to detect bearing faults in line-connected induction motors. In *2018 XIII International Conference on Electrical Machines (ICEM)*, 1841–1847.
- Guo, S., Ren, Y., Shi, S., Yang, L., and Lin, J. (2018). Rotating machinery vibration analysis of the rotary-laser scanning measurement system. In *2017 International Conference on Optical Instruments and Technology: Optoelectronic Measurement Technology and Systems*, volume 10621, 106210E. International Society for Optics and Photonics.
- Islam, R., Khan, S.A., and Kim, J.m. (2016). Discriminant feature distribution analysis-based hybrid feature

- selection for online bearing fault diagnosis in induction motors. *Journal of Sensors*, 2016.
- Kankar, P., Sharma, S.C., and Harsha, S. (2011). Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, 38(3), 1876 – 1886. doi:<https://doi.org/10.1016/j.eswa.2010.07.119>. URL <http://www.sciencedirect.com/science/article/pii/S0957417410007475>.
- Lei, Y. (2016). *Intelligent fault diagnosis and remaining useful life prediction of rotating machinery*. Butterworth-Heinemann.
- 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. In *PHM Society European Conference*, volume 3.
- Lu, S., Qian, G., He, Q., Liu, F., Liu, Y., and Wang, Q. (2020). In situ motor fault diagnosis using enhanced convolutional neural network in an embedded system. *IEEE Sensors Journal*, 20(15), 8287–8296.
- Mallat, S.G. (1989). A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, 11(7), 674–693.
- Markiewicz, M., Wielgosz, M., Bocheński, M., Tabaczyński, W., Konieczny, T., and Kowalczyk, L. (2019). Predictive maintenance of induction motors using ultra-low power wireless sensors and compressed recurrent neural networks. *IEEE Access*, 7, 178891–178902.
- Nishat Toma, R. and Kim, J.M. (2020). Bearing fault classification of induction motors using discrete wavelet transform and ensemble machine learning algorithms. *Applied Sciences*, 10(15), 5251.
- Ribeiro, F., Marins, M., Netto, S., and da Silva, E. (2017). Rotating machinery fault diagnosis using similarity-based models. doi:10.14209/sbrt.2017.133.
- Strang, G. and Nguyen, T. (1996). *Wavelet and Filter Banks*. Wellesley: Cambridge Press.
- Sugiyama, M. (2015). *Introduction to statistical machine learning*. Morgan Kaufmann.
- Toma, R.N., Prosvirin, A.E., and Kim, J.M. (2020). Bearing fault diagnosis of induction motors using a genetic algorithm and machine learning classifiers. *Sensors*, 20(7), 1884.
- Tsyppkin, M. (2013). Induction motor condition monitoring: Vibration analysis technique—a twice line frequency component as a diagnostic tool. In *2013 International Electric Machines & Drives Conference*, 117–124. IEEE.
- Webb, A. (2003). *Statistical Pattern Recognition*. Wiley InterScience electronic collection. Wiley.