

Processamento de Sinais de Vibração aplicado à Classificação de Falhas em Rolamentos

Rodrigo C. Campos¹, Gizele P. do Nascimento¹, Hudson C. Dalprá¹, Luiz A. Pinto¹

¹Programa de Pós-graduação em Engenharia de Controle e Automação
Instituto Federal do Espírito Santo (IFES), Serra, ES, Brasil

pintoluizalberto@gmail.com

Abstract. *This paper compares the performance of several classification algorithms applied to the bearing failures diagnosis. To build the models, 13 statistical descriptors were extracted from the vibration signals available in the Paderborn data set. The models were built in both time and time/frequency domains, using the wavelet transform, and the k-NN, SVM and Decision Tree algorithms were applied. The performances of the models were evaluated based on metrics of accuracy, precision, sensitivity, specificity, and F1-score. The average result obtained in all classifiers configurations was 98%.*

Resumo. *Esse trabalho compara o desempenho de diversos algoritmos de classificação aplicados 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-NN, SVM e Árvore de Decisão. Os desempenhos dos modelos foram avaliados com base nas métricas de acurácia, precisão, sensibilidade, especificidade e F1-score. O resultado médio obtido em todas as configurações dos classificadores foi 98%.*

1. Introdução

Motores são máquinas elétricas utilizadas em aplicações comerciais e industriais, fundamentais para o funcionamento dos processos com maior confiabilidade e disponibilidade, [Zhang et al. 2020]. Segundo [Zhang et al. 2020], falhas em motores podem ocasionar a parada de processos de uma indústria, por isso é importante diagnosticá-las logo no início, já que o tempo de inatividade não programado da máquina, pode alterar os prazos e entrega dos produtos e causar perdas financeiras consideráveis.

O monitoramento das condições dos motores elétricos industriais fornece informações que auxiliam o planejamento das intervenções de manutenção antes da ocorrência de falhas. Para tal, ferramentas inteligentes auxiliam esta supervisão, identificando condições anormais de funcionamento.

Falhas frequentes nos motores ocorrem nos rolamentos. De acordo com [Zhang et al. 2020], cerca de 30 a 40% das falhas em motores, afetam as condições operacionais e reduzem a vida útil do equipamento. Evitar ou minimizar a possibilidade de ocorrência de falhas é o papel da equipe de manutenção dentro do parque fabril.

Métodos inteligentes de diagnóstico de falhas em rolamentos com base na análise de sinais têm sido amplamente aplicados nas indústrias. Uma abordagem para diagnóstico

de falha com base na análise de sinais deve ser constituída, minimamente por três etapas básicas: (1) aquisição dos sinais do processo, (2) extração de descritores dos sinais para caracterizar as assinaturas das falhas e (3) classificação de diferentes condições de funcionamento com base nos descritores associados às falhas, [Islam et al. 2016]. Outra abordagem que têm se mostrado eficiente é a utilização da transformada *wavelet* [Mallat 1989] juntamente com os algoritmos de classificação. Nesse caso, os descritores das falhas são extraídos dos sinais do processo após os mesmos serem transformados para o domínio *wavelet*.

Esse trabalho investiga o diagnóstico de falhas em rolamentos de motores elétricos, a partir da análise de sinais de vibração. Para a realização dos experimentos, foi 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. Na etapa de classificação foram utilizados os algoritmos *k-Nearest Neighbour (k-NN)* [Islam et al. 2016], *Support Vector Machine (SVM)* [Zhang et al. 2020] e *Árvore de Decisão (TREE)* [Islam et al. 2016], que foram constituídos a partir de descritores estatísticos, extraídos tanto no domínio do tempo, quanto no domínio tempo/frequência, com a utilização dos filtros das famílias *Coiflet*, *Daubechies* e *Symlet*.

No que segue, este artigo está organizado em cinco seções: na Seção 2 é apresentada a Revisão Bibliográfica, a Seção 3 faz uma breve descrição dos algoritmos de classificação utilizados nos experimentos, na Seção 4 apresentam-se os Materiais e Métodos utilizados para a realização dos experimentos. Os Resultados obtidos estão apresentados na Seção 5 e, finalmente, na Seção 6 a Conclusão e discussão final são realizadas.

2. Revisão da Bibliografia

Diversas pesquisas envolvendo diagnósticos de falhas através de sinais de vibração vem sendo desenvolvidas nos últimos anos. Segundo [Toma et al. 2020] os sinais de vibração carregam informações ricas sobre condições do estado do rolamento e são comumente utilizados para diagnóstico de falhas nesses elementos. Falhas em motores têm recebido a atenção nos meios acadêmicos e industriais, pois ao detectar a falha e interpretá-la corretamente de forma precoce, evita-se uma parada de manutenção não programada e consequentemente, a interrupção da produção, [Toma et al. 2020, Toma and Kim 2020].

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 auto-

res 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.

Em [Barcelos et al. 2020] são utilizadas as transformadas, *wavelet* (família *Daubechies*) e *Hilber-Huang* dos sinais de corrente de um motor de indução trifásico para criar uma base de dados. Por meio de extração de característica dos sinais transformados, modelos de diagnóstico foram construídos para analisar as avarias nos rolamentos. Conforme os autores, o desempenho na classificação foi superior a 98%, concluindo ser possível, a utilização de algoritmos de Inteligência Artificial para classificar avarias em rolamentos de motores.

Os autores em [Toma et al. 2020] propõem uma abordagem híbrida baseada nos sinais de corrente dos motores. Para a representação dos sinais foram calculados descritores estatísticos, e para a seleção das variáveis a serem utilizadas pelos modelos foram aplicados Algoritmos Genéticos (GA). Na etapa de classificação foram utilizados os algoritmos *k-NN*, Árvore de Decisão e Floresta Aleatória. Os resultados experimentais mostram que os três classificadores alcançam desempenho geral acima de 97%.

Em [Apinantanapong and Nivesrangsang 2021] foi realizado um estudo de caso para diagnosticar seis tipos de falhas em rolamentos a partir dos sinais de vibração. Os sinais foram coletados utilizando uma técnica não intrusiva de detecção por acelerômetros. Para a representação dos sinais de vibração foram utilizadas abordagens no domínio do tempo e no domínio da frequência e para a classificação foram aplicados os algoritmos *SVM*, *k-NN* e Redes Neurais Artificiais (RNA). O melhor resultado (98% de acurácia) foi obtido com o classificador implementado com RNA.

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 de modelos para diagnósticos de falhas em processos industriais. Deve-se, entretanto destacar que o bom desempenho desses modelos dependerá, grandemente, da estrutura dos descritores extraídos dos sinais de vibração.

3. Referencial Teórico

Nessa seção estão brevemente descritas as ferramentas utilizadas no experimentos. A transformada *wavelet*, utilizada para a decomposição dos sinais de vibração, e os algoritmos *k-NN*, *SVM* e Árvore de Decisão aplicados para a construção dos classificadores.

3.1. *k-Nearest Neighbour - k-NN*

De acordo com [Islam et al. 2016], o *k-NN* é um classificador não paramétrico, amplamente utilizado devido à sua arquitetura simples e baixa complexidade computacional. Aplicado em tarefas de classificação e regressão, o *k-NN* faz uma estimativa da probabilidade de uma amostra pertencer ou não a uma classe específica. Para isso as distâncias da amostra desconhecida à todas as outras amostras são calculadas e a classe atribuída é a de maior ocorrência entre as *k* amostras mais próximas.

A métrica de distância comumente utilizada para variáveis contínuas é a distância euclidiana. Para variáveis discretas, outras métricas podem ser utilizadas, como, por exemplo a distância de *Hamming*. Nesta pesquisa foram utilizados os valores de $k = 1, 3, 5, 7$ e a métrica de distância utilizada foi a euclidiana.

3.2. Support Vector Machine - SVM

Support Vector Machine são classificadores lineares binários não-probabilísticos que se baseiam na teoria de aprendizado estatístico [Zhang et al. 2020]. 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. As funções *kernel* utilizadas nesse trabalho foram a linear, a gaussiana e a polinomial. 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 multi-classe *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.

3.3. Árvore de Decisão

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. A estratégia adotada pelo algoritmo é a dividir para conquistar, que reduz a complexidade de um problema dividindo-o em uma série de regras recursivas e encadeadas mais simples.

Uma Árvore de Decisão é composta por nós, que podem ser classificados em nós folha e nós de divisão. Nos nós de divisão são aplicadas as regras de decisão por meio de testes condicionais baseados nos valores dos atributos, criando assim ramificações que levam a novos nós. Quando um nó não possui regra de decisão, esse é denominado nó folha e, em problemas de classificação, podem ser considerados como as classes em que uma amostra pode pertencer, [Islam et al. 2016].

Para a construção de classificadores por meio de Árvore de Decisão é necessário que o número de ramos seja definido previamente. Neste trabalho, os números de nós utilizados para a construção de classificadores foram 10, 20, 30, 40, 50 e 100.

3.4. Transformada Wavelet

A transformada *Wavelet* (TW) [Mallat 1989] é uma ferramenta matemática para análise de sinais no domínio tempo/frequência, que decompõe o sinal com base em famílias de *wavelets*. A forma como a TW localiza as informações no domínio tempo/frequência, torna-o uma boa alternativa à análise de sinais não estacionários. Diferentemente das janelas de formato fixo usadas pela *STFT*, as famílias *wavelet* utilizam janelas de diferentes formas, como por exemplo as das famílias *Haar*, *Daubechies*, *Symlet*, *Morlet*, *Coiflet*. As funções *wavelet* são escaláveis, o que significa que a transformação *wavelet* é adaptável a uma ampla gama de resoluções baseadas em frequência e tempo. A *wavelet* mãe $\psi(t)$ pode ser expressa matematicamente por (1),

$$\psi_{s,\tau} = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right), \quad (1)$$

onde s representa o parâmetro de escala, τ o parâmetro de transformação e t é o tempo. A versão contínua da transformada *wavelet* está mostrada em (2). A *Transformada Wavelet Contínua - CWT* de um dado sinal $x(t)$ é definida como a soma ao longo do tempo de um sinal, multiplicada por versões escalonadas e deslocadas da função *wavelet* mãe (ψ).

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (2)$$

na qual $a \neq 0$, $x(t)$ é o sinal a ser analisado e $\psi(t)$ é a função base com duração limitada no tempo denominada *wavelet* mãe [Strang and Nguyen 1996].

A versão discreta da transformada pode ser diretamente obtida da *TWC* fazendo $a = a_0^j$ e $b = kb_0 a_0^j$, sendo j, k valores inteiros e $a_0 > 1$, $b_0 > 0$. Para $a_0 = 2$ e $b_0 = 1$, obtém-se um caso particular da transformada *wavelet* discreta denominada discretização diádica. 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.

Para a decomposição dos sinais de vibração no contexto dessa pesquisa foram utilizados os filtros das famílias, *Coiflet (coif5)*, *Daubechies (db4)* e *Symlet (sym8)* com nível de decomposição até o máximo possível.

4. Metodologia

Nesta seção estão descritas todas as etapas executadas na realização dos experimentos. São apresentados, o conjunto de dados, as técnicas de pré-processamento utilizadas, bem como as etapas de treinamento e classificação.

4.1. Conjunto de Dados

Na fase experimental foi utilizado o conjunto de dados *Paderborn*, [Lessmeier et al. 2016]. Na forma bruta original, o conjunto *Paderborn* é cons-

tituído por sinais de vibração e corrente de motores elétricos, em diversas condições de falhas, reais e simuladas, além da condição de funcionamento normal.

Para a aquisição dos sinais que constituem o conjunto *Paderborn*, foi utilizada a bancada de teste mostrada na Figura 1. 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.

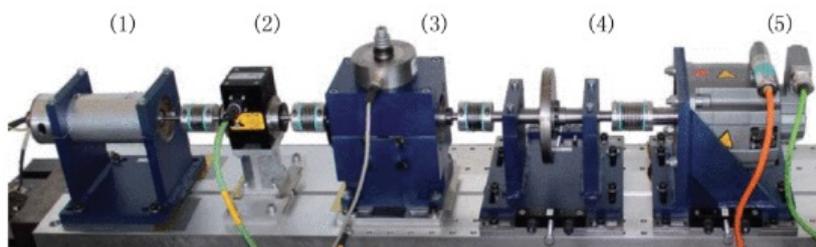


Figura 1. Bancada de Teste Paderborn.

Nesse trabalho, por ser uma abordagem consolidado na literatura, optou-se pela utilização dos sinais de vibração para o diagnóstico de falhas nos rolamentos. Os sinais de vibração foram coletados a partir de rolamentos que apresentaram falhas em condições reais de funcionamento, bem como de rolamentos nos quais foram inseridas falhas artificiais. Por melhor representarem as situações de funcionamento real, nessa pesquisa decidiu-se pela utilização dos sinais relacionados às falhas reais. Os modos de falha em condições reais de funcionamento disponíveis no conjunto de dados são: fadiga, desgaste, corrosão, erosão por eletricidade, deformação plástica, fratura, num total de seis modos de falha, além da condição de funcionamento normal.

Para formalizar o problema de reconhecimento de padrões, nesse trabalho, foram utilizados os modos de falha fadiga e deformação plástica em diferentes partes do rolamento. Dessa forma, o conjunto de dados utilizado para a construção dos modelos foi constituído por cinco classes de falha e a classe correspondente ao funcionamento normal.

O sinal bruto correspondente a um modo de funcionamento, normal ou em falha, foi coletado na forma de um vetor com 256.001 elementos. A partir do sinal bruto foram constituídas as matrizes das classes com 100 linhas de 2560 elementos às quais foram acrescentadas os rótulos das classes. Dessa forma, cada classe foi constituída por 100 amostras com 2561 variáveis. A Tabela I mostra as seis classes que constituem o conjunto de dados utilizado para a modelagem, bem como o código de identificação do arquivo correspondente no conjunto de dados original.

4.2. Extração de descritores estatísticos

Como uma técnica de compressão de sinais, e para reduzir o número de variáveis na etapa de classificação, de cada uma das amostras da matriz que caracteriza 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

Tabela 1. Classificação dos Defeitos

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

(*Xskewness*), Fator de forma (*Xshape*), a Raiz quadrada média (*Xrms*), o Fator de crista (*Xcrest*), o Valor de Pico a Pico (*Xpeak2peak*) e a Raiz da Soma do Quadrado (*Xrssq*), [Lei 2016, MATLAB 2010]. A Tabela 2 apresenta a formulação matemática de cada um dos parâmetros estatísticos.

É importante destacar o RMS (*root mean square*) ou raiz média quadrática de um sinal como um descritor eficiente para análise no tempo. Esse parâmetro corresponde à medida do conteúdo de energia da assinatura do sinal de vibração, amplamente utilizado na literatura em máquinas rotativas, [Ren et al. 2018] [Tsypkin 2013]. 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 com 13 descritores, obtidos a partir dos valores dos parâmetros estatísticos indicados na Tabela 2.

Tabela 2. Parâmetros estatísticos extraídos do sinal no domínio do tempo

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	$X_{rssq} = \sqrt{\sum_{n=1}^N x_n ^2}$

Os descritores para representação dos sinais de vibração foram calculados, inicialmente, com os sinais no domínio do tempo e posteriormente com os sinais no domínio *wavelet*. Nesse caso, os sinais foram transformados para o domínio *wavelet* com a utilização dos filtros *coif5*, *db4* e *sym8*, em todos os níveis de decomposição possíveis.

4.3. Treinamento e Classificação

Para a modelagem, o conjunto de dados foi particionado em 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 (TREE), que foram treinados no domínio do tempo e com a transformada *Wavelet*. Como métricas de avaliação de desempenho foram utilizadas acurácia, precisão, sensibilidade, especificidade e *FI-score*. Todos os testes foram realizados no Matlab, R2020a.

4.4. Métricas de Desempenho

Em problemas de classificação é muito comum o uso da matriz de confusão para verificar o desempenho dos modelos. Essa matriz reúne as informações sobre o número de predições corretas e incorretas de cada classe. A partir da matriz de confusão várias outras métricas podem ser obtidas para a análise de desempenho dos classificadores.

A Figura 2 apresenta a matriz de confusão num problema de duas classes no qual a classe positiva é denotada pelo sinal (+) e a classe negativa é denotada pelo sinal (-), dessa forma:

- TP (*True Positive*): corresponde ao número de exemplos da classe positiva classificados corretamente.
- TN (*True Negative*): corresponde ao número de exemplos da classe negativa classificados corretamente.
- FP (*False Positive*): número de exemplos que pertencem à classe negativa mas foram classificados incorretamente como sendo da classe positiva.
- FN (*False Negative*): número de exemplos pertencentes à classe positiva que foram incorretamente classificados como sendo da classe negativa.

		Classe Predita	
		+	-
Classe Verdadeira	+	TP	FN
	-	FP	TN

Figura 2. Matriz de confusão de 2 classes.

Fonte: Autoria própria.

A partir da matriz de confusão, várias outras medidas de desempenhos são derivadas, entre elas temos:

- Acurácia: corresponde à taxa de acerto, calculada pela soma dos valores da diagonal principal, dividido pelo numero total de elementos da matriz.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN}. \quad (3)$$

- Precisão: quantidade de exemplos positivos classificados corretamente entre todos aqueles preditos como positivos.

$$Precisão = \frac{TP}{TP + FP}. \quad (4)$$

- Sensibilidade: corresponde à taxa de acerto na classe positiva.

$$Sensibilidade = \frac{TP}{TP + FN}. \quad (5)$$

- Especificidade: avalia a capacidade do modelos para detectar resultados negativos.

$$Especificidade = \frac{TN}{FP + TN}. \quad (6)$$

- *F-measure* ou *f1-score*: média harmônica ponderada da precisão e revocação.

$$F_1 = \frac{2 \times prec \times recall}{prec + recall}. \quad (7)$$

5. Resultados

As tabelas 3, 4, 5, 6 apresentam os resultados dos testes no domínio do tempo e no domínio tempo/frequência. Em todos os testes os modelos foram obtidos com os treze descritores calculados a partir dos parâmetros estatísticos dos sinais de vibração. Os resultados registrados na Tabela 3 foram obtidos com os sinais no domínio do tempo, e os resultados das tabelas 4, 5, 6 foram obtidos com a utilização da transformada *Wavelet coif5*, *db4* e *sym8*, respectivamente, tendo os sinais sido decompostos em todos os níveis de resolução possíveis. Em todos os testes foram utilizados os algoritmos *k-NN* com 1, 3, 5 e 7 vizinhos, *SVM* com os *kernels* linear (Lin), gaussiano (Gau) e polinomial (Pol), e para a Árvore de Decisão (TREE) os teste foram realizados com 10, 20, 30, 40, 50 e 100 ramos. Os resultados mostrados nas tabelas foram os melhores obtidos em cada configuração de teste.

Tabela 3. Resultados da Classificação no Domínio do Tempo

Classif.	Acc	Prec.	Espc.	Sensb.	F1-Score
k-NN - k=3	0.9890	0.9889	0.9892	0.9889	0.9889
SVM - Gau.	0.9945	0.9946	0.9786	0.9944	0.9944
TREE - 50	0.9835	0.9842	0.9841	0.9833	0.9833

Tabela 4. Resultados da Classificação utilizando a Wavelet Coif 5

Classif.	Acc	Prec.	Espc.	Sensb.	F1-Score
k-NN - k=5	0.9890	0.9892	0.9892	0.9889	0.9889
SVM - Gau.	0.9727	0.9724	0.9732	0.9722	0.9722
TREE - 50	0.9945	0.9946	0.9946	0.9944	0.9944

Comparando os resultados da classificação com os sinais no domínio de tempo (Tabela 3), nota-se que os resultados obtidos com os três algoritmos são semelhantes.

Tabela 5. Resultados da Classificação Utilizando a Wavelet db4

Classif.	Acc	Prec.	Espc.	Sensb.	F1-Score
k-NN - k=3	0.9945	0.9946	0.9946	0.9944	0.9944
SVM - Gau.	0.9835	0.9835	0.9838	0.9833	0.9833
TREE - 50	0.9836	0.9833	0.9838	0.9833	0.9832

Tabela 6. Resultados da Classificação utilizando a Wavelet sym 8

Classif.	Acc	Prec.	Espc.	Sensb.	F1-Score
k-NN - k=5	0.9781	0.9785	0.9787	0.9778	0.9778
SVM - Gau.	0.9784	0.9784	0.9792	0.9778	0.9778
TREE - 20	0.9945	0.9946	0.9946	0.9944	0.9944

Não sendo possível afirmar que existe diferença estatística entre os valores das métricas em cada caso.

Em relação aos resultados dos modelos com os sinais no domínio *wavelet*, nota-se que, de forma geral, o desempenho dos modelos construídos com os três filtros *wavelet* utilizados na decomposição são semelhantes. Se analisarmos o desempenho dos modelos com base na acurácia, podemos dizer que os classificadores que utilizaram Árvore de Decisão foram ligeiramente melhores, tendo apresentado melhor valor de acurácia para 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 a *coif5*, com todos os classificadores, os melhores modelos foram obtidos no terceiro nível de resolução, assim como para o filtro *db4*. Para o filtro *sym8* não houve uma prevalência de um nível de resolução no resultado dos modelos. Dessa forma, é possível afirmar que a faixa de frequência relacionada com o terceiro nível de resolução melhor se ajusta aos 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 (Gau), em todos os casos, resultou nos melhores modelos, e para a Árvore de Decisão os melhores desempenhos foram obtidos com 50 ramos.

De forma geral, todos os classificadores 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 *wavelet* podem ser atribuídos a qualidade do conjunto de descritores 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 a ser modelado é tão, ou mais importante do que bons algoritmos de classificação.

6. Conclusões

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 vantajosa 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, 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 dos que algoritmos de *Deep Learning*.

Referências

- Apinantanapong, N. and Nivesrangsang, 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)*. IEEE.
- Barcelos, A. D. S., Mazzoni, F. M., and Cardoso, A. J. M. (2020). Análise de avarias em rolamentos, utilizando algoritmos de inteligência artificial. In *Anais do Congresso Brasileiro de Automática 2020*. sbabra.
- 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*.
- Gongora, W. S., Goedel, 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)*, pages 1841–1847.
- 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*, 2016:1–16.
- 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”. *PHM Society European Conference*, 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. (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.
- MATLAB (2010). *version 9.8.0 (R2020a)*. The MathWorks Inc., Natick, Massachusetts.
- Ren, Y., Shi, S., Yang, L., Lin, J., and Guo, S. (2018). Rotating machinery vibration analysis of the rotary-laser scanning measurement system. In Zhu, J., Xu, K., Dong, L., Tam, H.-Y., and Xiao, H., editors, *2017 International Conference on Optical Instruments and Technology: Optoelectronic Measurement Technology and Systems*. SPIE.
- Ribeiro, F., Marins, M., Netto, S., and da Silva, E. (2017). Rotating machinery fault diagnosis using similarity-based models.
- Strang, G. and Nguyen, T. (1996). *Wavelets and filter banks*. Wellesley-Cambridge Press, Wellesley, MA, 2 edition.
- Toma, R. N. 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.
- 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.
- Tsympkin, 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*. IEEE.
- Zhang, S., Zhang, S., Wang, B., and Habetler, T. G. (2020). Deep learning algorithms for bearing fault diagnostics—a comprehensive review. *IEEE Access*, 8:29857–29881.