

Diagnóstico de Falhas em Rolamentos de Motores Elétricos com Base na Análise da Assinatura da Corrente do Motor

Marcos Rômulo de Oliveira

Pós-Graduação em Engenharia de Controle e Automação
Instituto Federal do Espírito Santo
Serra, Brasil
marcosromulodeoliveira@gmail.com

Luiz Alberto Pinto

Pós-Graduação em Engenharia de Controle e Automação
Instituto Federal do Espírito Santo
Vitória-ES, Brasil
luiz.pt@ifes.edu.br

Cassius Zanetti Resende

Pós-Graduação em Engenharia de Controle e Automação
Instituto Federal do Espírito Santo
Vitória-ES, Brasil
cassiusresende@gmail.com

Abstract—This article presents a comparative analysis of the performance of classification algorithms applied to fault diagnosis in electric motor bearings. To represent the faults, 13 statistical descriptors of the electric current signals available in the *Paderborn* dataset were extracted. The classification problem consisted of nine failure classes in addition to the normal operating condition class. The models were built both in the time domain and in the time scale domain, using *wavelet* transform filters, *Coiflet 5*, *Daubechies 4 (Daub 4)* and *Symlet 8*, at predefined resolution levels. The *k-NN*, *SVM* and *Decision Tree* algorithms were used to build the models. The performance of the models was evaluated based on the metrics of accuracy, sensitivity and F1 score. The best accuracy results were obtained using the SVM algorithm, with *Symlet* and *Coiflet 5* filters, reaching a value of 0.9967%. The article's main contribution, in addition to the use of *Wavelets* and *SVM* combined, was that it demonstrated results that were comparable when using electric current signals as entry to vibration signals that are already widely used in the industry and that the use of the *Wavelet* Transform, along which *Machine Learning* algorithms, when using good descriptors, can be a viable solution to implement diagnostic systems automatic detection of more accurate faults in electric motor bearings.

Índice de Termos—bearing failure classification, electric motors, support vector machine, electric current signal, pattern recognition

I. INTRODUÇÃO

Os motores elétricos são os principais componentes responsáveis pelo movimento em máquinas e equipamentos em um parques industriais. Por serem indispensáveis para a continuidade e a confiabilidade dos processos produtivos, é importante a implementação de uma estratégia de manutenção para prevenir e reduzir a ocorrência de falhas nesses equipamentos, e quando da ocorrência, os efeitos destas sobre os equipamentos e processos sejam mitigados. A prevenção da ocorrência de falhas na indústria tem como consequência

imediate, a redução de paradas não programadas, redução dos custos de manutenção e o aumento da produção.

Diversos tipos de falhas, de natureza elétrica e/ou mecânica, podem afetar o funcionamento dos motores elétricos, tais como: sobrecarga, desalinhamento, desbalanceamento do eixo, transientes de tensão, distorções harmônicas, fases desbalanceadas e desgaste dos mancais de rolamentos.

De acordo com [1], a maior parte das falhas em motores elétricos ocorrem nos mancais de rolamentos. A função dos mancais é dar suporte mecânico às partes rotativas, reduzir o coeficiente de atrito do movimento e garantir a precisão da rotação. Uma vez que ocorram falhas nestes componentes, a estabilidade de todo o conjunto pode ser afetada, provocando danos ao equipamento e condições inseguras para os operadores. As principais causas de desgaste dos rolamentos são, sobrecarga do motor, lubrificação inadequada, vedação ineficaz, tensões induzidas no eixo, desalinhamento, contaminações, entre outras.

Uma abordagem de manutenção que tem se mostrado eficiente, e por isso, amplamente utilizada nas indústrias, é o monitoramento contínuo das condições de funcionamento dos equipamentos com a utilização de sistemas de instrumentação para aquisição, processamento e análise das variáveis críticas dos processos. Tal abordagem permite identificar falhas de forma incipiente, possibilitando que intervenções sejam programadas para correção das mesmas. Ações de manutenção antecipadas podem evitar a consolidação das falhas e a consequente parada do equipamento por quebra ou falha total.

A integração entre modernas técnicas de instrumentação e algoritmos de *Machine Learning*, tem possibilitado o desenvolvimento de eficientes sistemas de detecção e diagnóstico de falhas em rolamentos de motores elétricos com base na análise dos sinais produzidos por esses equipamentos. Uma

abordagem para diagnóstico de falhas baseada em análise de sinais, de forma geral, é constituída pelas três etapas a seguir: (1) aquisição dos sinais do processo, (2) extração de descritores dos sinais para caracterizar as assinaturas das falhas e (3) construção de modelos para classificação das falhas ocorridas, dentro de um conjunto de falhas pré-determinadas, [2].

Sistemas de detecção e diagnóstico de falhas em mancais de rolamento, de forma geral, utilizam descritores extraídos de sinais de vibração [3]–[5]. Contudo, a necessidade da aquisição de instrumentação específica para a aquisição dos sinais de vibração, torna esse procedimento custoso, quando comparado às técnicas que utilizam a Análise da Assinatura da Corrente do Motor (*Motor Current Signature Analysis - MCSA*), que requer apenas a aquisição do sinal de corrente, o que pode ser obtido por instrumentos comumente disponíveis nos laboratórios.

Esse trabalho investiga o diagnóstico de falhas em rolamentos de motores elétricos, a partir da análise de sinais de corrente elétrica. Para a realização dos experimentos, foi utilizado o conjunto de dados *Paderborn* [6], 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)*, *Support Vector Machine (SVM)* e *Árvore de Decisão (TREE)*, que foram construídos 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 II são apresentados os Trabalhos Correlatos, a Seção III faz uma breve descrição dos algoritmos de classificação utilizados nos experimentos, na Seção IV é apresentada a Metodologia utilizada para a realização dos experimentos. Os Resultados obtidos e a correspondente discussão estão apresentados na Seção V e, finalmente, na Seção VI as Conclusões derivadas da realização da pesquisa são apresentadas.

II. TRABALHOS CORRELATOS

Nos últimos anos, [7], tem havido um crescente interesse no uso de sinais de corrente elétrica para a previsão de falhas em rolamentos de motores elétricos. Sinais de corrente encapsulam as características e mudanças ocorridas nos equipamentos e processos. Uma vez que sinais de corrente contém as assinaturas de falhas, eles podem ser utilizados para implementar sistemas de detecção e diagnóstico de falhas em rolamentos de motores.

Um dos estudos mais recentes nessa área foi conduzido por [8]. Neste estudo, os autores utilizaram sinais de corrente para treinar um classificador construído com a utilização do algoritmo *Support Vector Machine (SVM)*. De acordo com os autores, o classificador SVM apresentou acurácia de 99,5% na detecção das falhas nos rolamentos.

Outro estudo recente foi desenvolvido por [9]. Neste estudo, os autores utilizaram sinais de corrente para treinar uma rede

neural profunda (*Deep Neural Network - DNN*). O classificador baseado na *DNN* obteve uma acurácia de 99,7% na detecção de falhas dos rolamentos da bancada experimental utilizada para a obtenção dos sinais.

Os autores em [10], usaram o algoritmo Floresta Aleatória para classificar falhas em rolamentos com uma acurácia de 99,6%. O artigo [11], utilizou redes neurais profundas *DNN* para classificar falhas em rolamentos com acurácia de 99,7%. O artigo de [12], utilizou o algoritmo *k-NN* para classificar sinais de corrente elétrica de um motor elétrico cujos rolamentos apresentaram diferentes condições de falha. Para a realização dos experimentos, os autores utilizaram o conjunto de dados da SKF [13], que é constituído por sinais de corrente referentes a quatro condições de falha em rolamentos: falha na pista externa, falha na pista interna, falha na esfera e falha no rolo. Segundo os autores, o algoritmo *k-NN* foi apresentado uma acurácia de 99,7%.

Em [14], os pesquisadores utilizaram sinais de corrente elétrica para treinar um modelo construído utilizando o algoritmo *Árvore de Decisão*. Os autores relataram uma acurácia de 99,4% na detecção de falhas em rolamentos. Em [15], os pesquisadores utilizaram sinais de corrente para treinar um modelo de regressão baseado em *Árvore de Decisão*. A *Árvore de Decisão* regressora foi capaz de prever a vida útil remanescente dos rolamentos com uma acurácia de 99,5%.

Estes estudos sugerem que os sinais de corrente elétrica, em conjunto com algoritmos de *Machine Learning*, podem ser utilizados com sucesso para detectar e diagnosticar falhas em rolamentos de motores elétricos, bem como prever a ocorrência destas. Além disso, a introdução de novos algoritmos de *Machine Learning* e *Deep Learning*, associados a métodos de transformação dos sinais, tais como, a *Short Time Fourier Transform (STFT)* e a Transformada Wavelet Discreta (TWD), indicam que a detecção e predição de falhas em rolamentos de motores elétricos utilizando sinais de corrente elétrica continuará sendo uma área de pesquisa promissora nos próximos anos.

III. REFERENCIAL TEÓRICO

As ferramentas utilizadas na etapa experimental do desenvolvimento dessa pesquisa estão brevemente descritas nesta Seção. São apresentadas as fundamentações teóricas sobre a *Transformada Wavelet*, ferramenta matemática utilizada para a decomposição dos sinais de corrente elétrica e sua transformação para o domínio tempo/escala, bem como os principais conceitos relacionados aos algoritmos *k-NN*, *SVM* e *Árvore de Decisão*, utilizados para a construção dos modelos de classificação.

A. *k-Nearest Neighbour - k-NN*

O *k-NN* é um classificador não paramétrico, amplamente utilizado devido à sua arquitetura simples e baixa complexidade computacional, [2]. Ainda de acordo com [2], o *k-NN* pode ser utilizado em tarefas de classificação e regressão com o objetivo de calcular a probabilidade de que uma amostra desconhecida pertença a uma classe específica. Para isso, as

distâncias entre a amostra desconhecida e todas as amostras conhecidas do espaço amostral são calculadas e a classe atribuída à amostra desconhecida será a de maior ocorrência entre a k amostras mais próximas.

Para variáveis contínuas, a distância euclidiana é a métrica de distância mais popular. É possível utilizar outras métricas para variáveis discretas, como a distância de *Hamming*. Nesse trabalho foram utilizados os valores de $k = 1, 3, 5, 7$ e a métrica de distância euclidiana. Na Figura 1 e apresentada a estratégia de classificação empregada pelo k -NN. Neste exemplo em que o valor de k é igual a 4, a amostra desconhecida AD será atribuída a classe C3, por ser a classe da maior parte das k amostras.

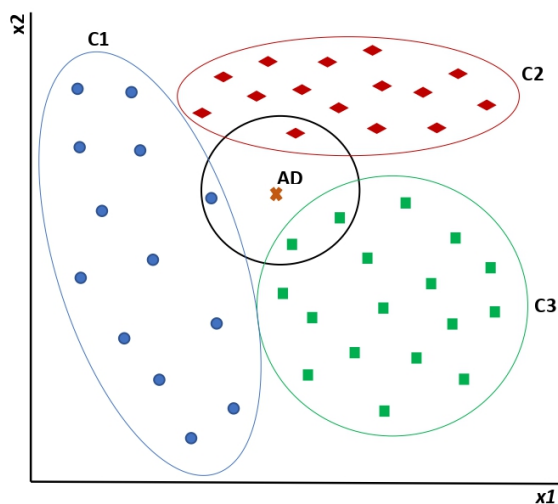


Fig. 1. Exemplo ilustrativo do algoritmo k -NN com $k=4$
Fonte: Autoria própria

B. Support Vector Machine - SVM

Support Vector Machine são classificadores lineares binários não probabilísticos que se baseiam na teoria de aprendizado estatístico [16]. Para a separação das classes, o algoritmo procura um hiperplano de separação de maneira que a distância entre dois objetos que estão mais próximos um do outro seja maximizada. Quando aplicado a problemas não lineares, o SVM utiliza funções *kernel*. Tais funções transformam os dados não linearmente separáveis, representando-os em um espaço de dimensão superior, onde é assegurado a obtenção de um limite de decisão linear. Por ser um classificador binário, métodos multiclasse são necessários para resolver problemas de classificação que incluam mais de duas classes. Neste trabalho foram utilizadas as funções *kernel linear*, *gaussiana*, *rbf* e *polinomial*, e o método multiclasse *one-vs-one*.

No método *one-vs-one*, são construídos $n(n-1)/2$ classificadores binários para as n classes do problema. Cada um desses classificadores binários é responsável por determinar apenas um par de classes. O resultado final é obtido por votação, e uma amostra é atribuída à classe mais votada. Na Figura 2 é apresentado o espaço amostral após a utilização do

algoritmo SVM, ilustrando o hiperplano de separação ótimo encontrado pelo SVM, bem como os vetores de suporte.

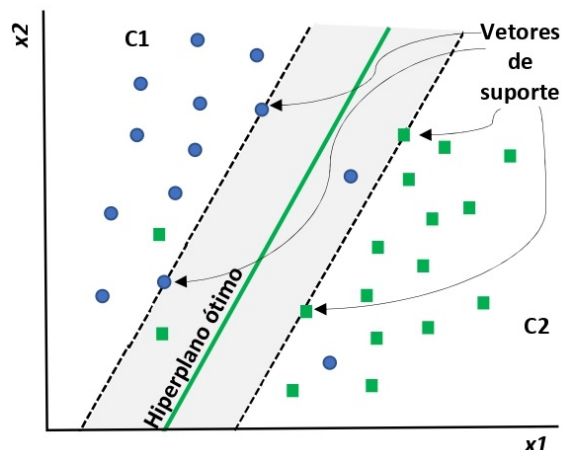


Fig. 2. Representação do espaço amostral com o algoritmo SVM
Fonte: Autoria própria

C. Árvore de Decisão

Algoritmos de aprendizado baseados em árvore de decisão constituem uma grande família de métodos supervisionados não paramétricos que podem ser utilizados para construção de modelos de regressão e classificação. O algoritmo se baseia na estratégia dividir para conquistar, que reduz a complexidade de um problema dividindo-o em um conjunto mais simples de regras recursivas encadeadas.

Uma árvore de decisão é constituída por nós e ramos, (Figura 3). Os nós podem ser classificados em *nós folha* e *nós de divisão*. Um nó é chamado de *nó folha* quando não possui uma regra de decisão associada. Em problemas de classificação, as classes a que uma amostra pode pertencer estão associadas aos *nós folha*. Para a atribuição de uma classe a uma amostra desconhecida, regras de decisão são aplicadas aos nós de divisão por meio de testes condicionais baseados nos valores dos atributos, criando novos ramos que resultam em novos nós [15].

Para a construção de classificadores por meio de Árvore de Decisão é necessário que o número de ramos e a regra de divisão sejam definidos previamente. Neste trabalho, os números de nós utilizados para a construção de classificadores foram 10, 20, 30, 40, 50 e 100, e o critério de divisão utilizado foi o *gdi*.

D. Transformada Wavelet

A transformada *Wavelet* (TW) [16] 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-a uma boa alternativa à análise de sinais, quando aplicada a sinais não estacionários. Diferentemente das janelas de formato fixo usadas pela *STFT*, as famílias *wavelet* utilizam janelas de diferentes formas, como

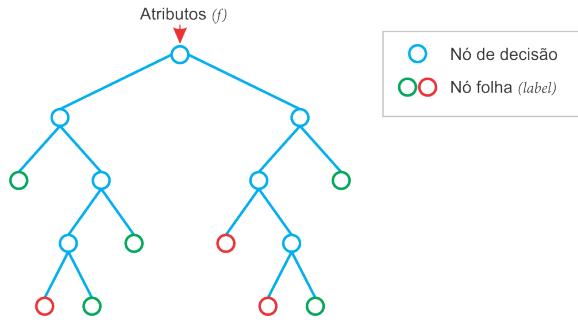


Fig. 3. Exemplo de um modelo de Árvore de Decisão
Fonte: Autoria própria.

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 a soma de todos os sinais ao longo do tempo, multiplicada por todas as versões escalonadas e deslocadas da função *wavelet* mãe ($\psi(t)$).

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

na qual $a \neq 0$, $x(t)$ é o sinal a ser analisado e $\psi(t)$ é a função básica que tem uma duração limitada no tempo chamada *wavelet* mãe [18].

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. Na Figura 4 é apresentado o esquema do banco de filtro de decomposição para cálculo da *TWD*. Nesse exemplo, foi considerado três níveis de resolução para a decomposição do sinal de entrada $f(x)$.

Para a decomposição dos sinais de corrente elétrica 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.

IV. METODOLOGIA

Nesta seção estão descritas todas as etapas executadas na realização dos experimentos. São apresentados, o conjunto de

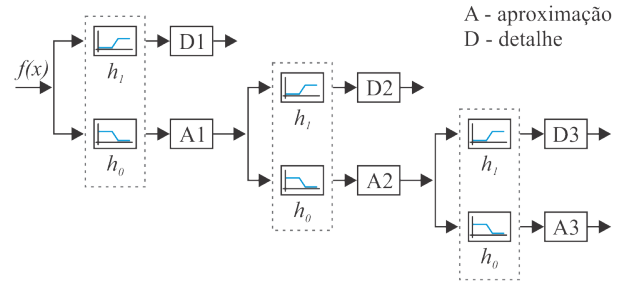


Fig. 4. Decomposição do sinal $f(x)$ utilizando a transformada *wavelet*
Fonte: Autoria própria.

dados, as técnicas de pré-processamento utilizadas, bem como as etapas de treinamento e classificação.

A. Conjunto de Dados

Na fase experimental foi utilizado o conjunto de dados *Paderborn*, [6]. Na configuração original, o conjunto *Paderborn* é constituído 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, foi utilizada a bancada de teste apresentada na Figura 5. 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 [6] está apresentado o procedimento experimental detalhado para aquisição dos sinais.




Fig. 5. Bancada de Teste Paderborn.
Fonte: [6]

Considerando as desvantagens da utilização dos sinais de vibração em relação aos sinais de corrente para a construção de modelos de diagnósticos de falhas, neste trabalho, para a construção dos modelos, optou-se pela utilização dos sinais de corrente. Para a obtenção dos sinais, os rolamentos foram submetidos a testes de vida útil acelerado, e as falhas registradas ocorreram em condições reais de operação do conjunto. O teste de vida útil acelerado realizado, consistiu na aplicação de uma força radial no rolamento, superior aos valores suportados em condições normais de funcionamento. Além disso, para a lubrificação do rolamento foi utilizado óleo com baixa viscosidade. A combinação das duas ações (força radial elevada e lubrificação inadequada), aceleraram o aparecimento de falhas nos rolamentos.

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 e em diferentes extensões. Além da condição normal de funcionamento, nove classes com diferentes tipos de falhas estão disponíveis.

Os sinais originais correspondentes aos modos de funcionamento, “normal” ou “falha”, foram coletados na forma de vetores com 256.001 elementos, por 4s à uma frequência de 64Khz. Para a constituição da matriz de classes, os sinais originais foram particionados em segmentos com 2560 variáveis, em que cada segmento constituiu uma amostra no problema de reconhecimento de padrões. Após a atribuição do rótulo das classes, cada amostra na matriz de classificação ficou constituída por 2561 variáveis. Na Tabela 5 é apresentada as dez classes que constituem o conjunto de dados utilizado para a construção dos modelos de diagnóstico, bem como o código de identificação do arquivo correspondente no conjunto de dados original.

TABELA I
CLASSIFICAÇÃO DAS FALHAS

Classe	Tipo de Falha	Código
1	Funcionamento Normal	K001
2	Fadiga na pista externa - extensão 1	KA04
3	Deformação na pista externa - extensão 1	KA15
4	Fadiga na pista interna - extensão 1	KI04
5	Fadiga nas pistas, interna e externa - extensão 2	KB23
6	Deformação nas pistas, interna e externa - extensão 1	KB27
7	Fadiga na pista externa - extensão 2	KA16
8	Fadiga nas pistas, interna e externa - extensão 3	KB24
9	Fadiga na pista interna - extensão 3	KI16
10	Fadiga na pista interna - extensão 2	KI18

B. Extração de Descritores Estatísticos

A ocorrência de falhas altera o regime de funcionamento do motor de indução, tornando o sinal de corrente não estacionário. De forma geral, sinais não estacionários no domínio do tempo, podem ser bem representados por parâmetros estatísticos. A utilização de parâmetros estatísticos para representação dos sinais de corrente pode ser visto como uma técnica de compressão, em que o sinal é representado por um conjunto reduzido de descritores que ainda mantêm as informações relevantes para a construção dos modelos.

Para a representação dos sinais de corrente na etapa de construção dos modelos, 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 ($X_{skewness}$), 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}), [19], [20]. Na Tabela II é apresentada a formulação matemática de cada um dos parâmetros estatísticos utilizados neste trabalho.

É importante destacar o valor RMS (*root mean square*) ou raiz média quadrática de um sinal como um descritor eficiente para análise de sinais no domínio do tempo. Esse parâmetro corresponde à medida do conteúdo de energia da assinatura do sinal de corrente, amplamente utilizado na literatura em máquinas rotativas, [21] [22]. Após a extração e cálculo dos parâmetros estatísticos dos sinais de corrente, o conjunto de dados ficou constituído por 10 classes, todas contendo 100 amostras, com exceção da classe 8, que possuía 103 amostras. Desta forma, o conjunto de dados utilizados na etapa de construção dos modelos tinha 1003 amostras e 13 descritores, constituídos pelos valores dos parâmetros estatísticos indicados na Tabela II.

TABELA II
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 utilizados para representação dos sinais de corrente, inicialmente, foram calculados com os sinais no domínio do tempo e, posteriormente, no domínio tempo/escala. Para a obtenção da representação dos sinais no domínio tempo/escala, foram empiricamente selecionados os filtros *wavelet Symlet 8*, *Daubechies 4 (Daub 4)* e *Coiflet 5*, que, para a construção dos modelos foram decompostos nos níveis de resolução 4, 3 e 2, respectivamente. Assim como ocorreu na escolha dos filtros *wavelet* utilizados para a decomposição dos sinais, a definição dos níveis de resolução, também foi realizada de forma empírica.

C. Treinamento e Classificação

Para a construção dos modelos de diagnóstico, 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*, greenos resultados foram obtidos utilizando o conjunto de teste. Os modelos foram obtidos utilizando os algoritmos *k-NN*, *SVM* e Árvore de Decisão (TREE), que foram treinados no domínio do tempo e no domínio tempo/escala (domínio *Wavelet*). Como métricas de avaliação de desempenho foram utilizadas acurácia, sensibilidade e *F1-score*. Todos os testes foram realizados no *Matlab*, R2020a.

V. RESULTADOS E DISCUSSÃO

As tabelas III, IV e V apresentam os resultados dos testes no domínio do tempo e no domínio tempo/escala. Em todos os testes foram utilizados os algoritmos *k-NN* com 1, 3, 5 e 7 vizinhos, *SVM* com os *kernel*s linear (lin), gaussiano (gau), polinomial (pol) e rbf. Para a Árvore de Decisão (TREE) os testes foram realizados com 10, 20, 30, 40, 50 e 100 ramos. Em todos os testes (tanto no domínio do tempo como no domínio tempo/escala), os modelos foram obtidos com os 13 descritores calculados a partir dos parâmetros estatísticos dos sinais de corrente elétrica. Analisando os resultados obtidos com os classificadores construídos com o *k-NN*, pode-se observar que os modelos que foram implementados no domínio *wavelet* utilizando o filtro *Symlet 8* apresentaram melhor desempenho do que os modelos no domínio do tempo e no domínio *wavelet* com os filtros *Daubechies 4* e *Coiflet 5*. O melhor resultado obtido com o *k-NN* foi *Acurácia* = 0.9773, *Sensibilidade* = 0.9767 e *F1-Score* = 0.9765, com os modelos no domínio *wavelet*, com o filtro *Symlet 8* e *k* = 5.

TABELA III
RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO O *k-NN*

Domínio	Nível	k	Acurácia	Sensibilidade	F1
Tempo	-	1	0.9042	0.8967	0.8951
		3	0.8981	0.8900	0.8901
		5	0.8910	0.8833	0.8829
		7	0.8460	0.8267	0.8270
		Symlet 8	4	1	0.9770
Daub 4	3	1	0.8490	0.8333	0.8322
		3	0.8681	0.8567	0.8555
		5	0.8890	0.8800	0.8790
		7	0.8589	0.8467	0.8434
Coiflet 5	2	1	0.8613	0.8467	0.8462
		3	0.8687	0.8567	0.8557
		5	0.8408	0.8233	0.8200
		7	0.8577	0.8433	0.8427

Para os modelos construídos com o *SVM* (Tabela IV), nota-se o superior desempenho dos modelos construídos no domínio *wavelet*, que com algumas exceções, foram superiores aos modelos no domínio do tempo. Com exceção dos modelos que utilizaram o filtro *Symlet 8*, os piores resultados foram obtidos com o *kernel* linear. Por sua vez, o *gaussiano* (gau) foi o que possibilitou a construção do modelo com o melhor desempenho com o filtro (*Coiflet 5*).

TABELA IV
RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO O *SVM*

Domínio	Nível	kernel	Acurácia	Sensibilidade	F1
Tempo	-	gau	0.9469	0.9433	0.9433
		rbf	0.9169	0.9100	0.9106
		pol	0.9837	0.9833	0.9834
		lin	0.8245	0.8000	0.7803
Symlet 8	4	gau	0.9837	0.9833	0.9834
		rbf	0.9870	0.9867	0.9868
		pol	0.9967	0.9967	0.9967
		lin	0.9869	0.9867	0.9867
Daub 4	3	gau	0.9805	0.9800	0.9801
		rbf	0.9836	0.9833	0.9833
		pol	0.9772	0.9767	0.9768
		lin	0.9613	0.9600	0.9602
Coiflet 5	2	gau	0.9967	0.9967	0.9967
		rbf	0.9771	0.9767	0.9768
		pol	0.9771	0.9767	0.9767
		lin	0.8975	0.8900	0.8883

Em relação aos modelos construídos com a Árvore de Decisão (Tabela V), observa-se que as médias dos desempenhos dos modelos no domínio do tempo em todas as configurações da transformada *wavelet* são similares. Entretanto, o melhor resultado foi o do modelo no domínio do tempo com *NRamos* = 100.

TABELA V
RESULTADOS DA CLASSIFICAÇÃO UTILIZANDO A ÁRVORE DE DECISÃO

Domínio	Nível	NRam	Acurácia	Sensibilidade	F1
Tempo	-	10	0.8963	0.8833	0.8790
		30	0.9653	0.9633	0.9635
		50	0.9614	0.9600	0.9598
		100	0.9901	0.9900	0.9900
Symlet 8	4	10	0.7906	0.6767	NaN
		30	0.9675	0.9667	0.9668
		50	0.9576	0.9567	0.9565
		100	0.9708	0.9700	0.9699
Daub 4	3	10	0.9350	0.9300	0.9281
		30	0.9714	0.9700	0.9699
		50	0.9708	0.9700	0.9698
		100	0.9836	0.9833	0.9831
Coiflet 5	2	10	0.8779	0.8567	NaN
		30	0.9805	0.9800	0.9801
		50	0.9457	0.9433	0.9434
		100	0.9806	0.9800	0.9800

A Tabela VI e a Figura 6 contém os melhores resultados obtidos com cada algoritmo de classificação e a configuração do classificador em que o resultado foi obtido. Merece ser destacado também que os melhores modelos obtidos com os algoritmos *SVM* e Árvore de Decisão apresentaram desempenho significativamente superior ao melhor modelo construído com o algoritmo *k-NN*. Como pode ser visto na Tabela VI, o modelo construído utilizando Árvore de Decisão com 100 ramos no domínio do tempo apresentou desempenho comparável aos melhores modelos construídos no domínio tempo/escala. Contudo, os modelos construídos no domínio tempo/escala, com a transformação dos sinais de corrente

utilizando a transformada *wavelet* são mais robustos a ruídos. Para se entender a maior robustez dos modelos construídos no domínio tempo/escala, quando comparados aos modelos no domínio do tempo, deve-se considerar que para a implementação da transformada *wavelet*, filtros passa-altas e passa-baixas (vide Seção III.D) são aplicados aos sinais no domínio do tempo, eliminando ruídos dos sinais.

TABELA VI
MELHORES RESULTADOS OBTIDOS EM CADA ALGORITMO

Algoritmo	Domínio	Acurácia	Sensibilidade	F1
k-NN	Wavelet	0.9773	0.9767	0.9765
SVM	Wavelet	0.9967	0.9967	0.9967
TREE	Tempo	0.9901	0.9900	0.9900




Fig. 6. Melhores Resultados Obtidos em cada Algoritmo.

Fonte: autor

Na Tabela VII e na Figura 7 é apresentado os modelos com os melhores desempenhos considerando o domínio de modelagem e o tipo de filtro utilizado. Pode ser notado que os melhores resultados com a transformada *wavelet*, foram obtidos com modelos construídos com *SVM*, ao passo que no domínio do tempo o melhor modelo utilizou o algoritmo Árvore de Decisão (TREE). Esse resultado mostra a superioridade dos classificadores implementados com o algoritmo *SVM* quando utilizam a transformada *wavelet*. Nesse caso, o desempenho superior do *SVM* pode ser explicado pelo fato de que, no domínio *wavelet*, os sinais de corrente elétrica são filtrados, tendo os ruídos dos sinais eliminados, o que favorece o desempenho dos classificadores obtidos por meio do *SVM*.

TABELA VII
MELHORES RESULTADOS CONSIDERANDO O DOMÍNIO DE MODELAGEM

Domínio	Algoritmo	Acurácia	Sensibilidade	F1
Tempo	TREE	0.9901	0.9900	0.9900
Symlet 8	SVM	0.9967	0.9967	0.9967
Daub 4	SVM	0.9836	0.9833	0.9833
Coiflet 5	SVM	0.9967	0.9967	0.9967

Os resultados mostram que, a maioria dos melhores resultados, quando comparadas configurações de modelagem correspondentes, foram obtidas no domínio *wavelet*. Contudo, os experimentos demonstram que é possível obter bons resultados no domínio do tempo. Nesse contexto, pode-se argumentar que a possibilidade da construção de modelos com boa capacidade de classificação em ambos os domínios de modelagem,




Fig. 7. Melhores Resultados Considerando o Domínio de Modelagem.

Fonte: autor

podem ser atribuídos a qualidade do conjunto de descritores utilizados para representar os sinais de corrente. De fato, a utilização de descritores com boa capacidade de descrição do comportamento do fenômeno a ser representado é tão, ou mais importante do que bons algoritmos de classificação.

Como o *SVM* é um algoritmo robusto que não é sensível ao ruído, ele pode lidar com dados complexos e não lineares e pode ser usado para classificar um grande número de pontos de dados. Já *wavelet* pode decompor o sinal em diferentes bandas de frequência eliminando ruídos, o que pode ajudar a identificar as frequências específicas associadas a uma falha específica. A combinação da transformada *wavelet* e *SVM* pode ajudar a superar as limitações de cada técnica individualmente, e assim se explica o desempenho superior quando da utilização destas técnicas combinadas.

VI. CONCLUSÕES

Neste artigo foi analisado o desempenho de algoritmos de classificação de falhas em rolamentos de motores elétricos através de sinais de corrente. 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.

Os experimentos realizados indicam que a utilização da transformada *wavelet* favorece a construção de modelos com boa capacidade de classificação, independente da escolha do algoritmo de classificação e da configuração do classificador. Como a implementação da transformada *wavelet* requer a construção de filtros passa-baixas e passa-altas para a extração dos descritores, os sinais originais passam por uma etapa de filtragem, o que elimina ruídos dos sinais, possibilitando melhor desempenho dos modelos na etapa de classificação. Os resultados mostram a superioridade do algoritmo *SVM* e do domínio *wavelet* para a construção dos modelos. Considerando o algoritmo utilizado para a construção dos modelos (Tabela VI), dois dos três melhores resultados foram obtidos no domínio *wavelet*. Considerando o domínio da modelagem (Tabela VII), três dos quatro melhores modelos foram obtidos com o *SVM*, todos no domínio *wavelet*. De fato, a filtragem dos sinais de corrente favorece o desempenho de modelos construídos com o *SVM*. Como principal contribuição, além da utilização das *wavelets* e do algoritmo *SVM*, o artigo apresentou resultados compatíveis utilizando sinais de corrente

elétrica como entrada quando comparados com sinais de vibração largamente utilizados na indústria atualmente.

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*.

Este trabalho ainda deixa lacunas para futuros trabalhos como a seguir:

- 1) Executar experimentos com dados obtidos em ambiente industrial o mais próximo da aplicação. Devido à sua complexidade, a utilização de dados reais numa aplicação industrial pode ser um desafio significativo, mas também pode fornecer uma validação mais robusta dos resultados.
- 2) Investigação do uso de técnicas de *Deep Learning*, tais como redes neurais convolucionais e redes neurais recorrentes, pode possibilitar a extração de informações importantes de séries temporais, como as informações encontradas em sinais de vibração.
- 3) Avaliação de desempenho em tempo real de algoritmos desenvolvidos para permitir uso prático em sistemas de monitoramento de máquinas. Esta etapa envolve avaliar a velocidade de processamento dos algoritmos e utilizar técnicas de otimização para agilizar a detecção de erros.

REFERÊNCIAS

- [1] M.A. Khan, M.A. Khan, and M.I. Asghar, "Failure Analysis of Electric Motors: A Review", *Journal of Mechanical Engineering*, 2022, 68(2), 1-12.
- [2] Chen, Y., Zhang, Y., Liu, S., Zeng, J., "A comprehensive review of K-nearest neighbors: Algorithms, extensions, and applications", *Pattern Recognition Letters*, vol. 150, Article 1-10, 9 páginas, 2022, doi:10.1155/2016/7145715
- [3] R. N. Toma, A. E. Prosvirin, e J.M. Kim, "Bearing Fault Diagnosis of Induction Motors Using a Genetic Algorithm and Machine Learning Classifiers", *Sensors* vol. 20, n. 7, pp 1884, 2020. doi: 10.3390/s20071884.
- [4] A. S. Barcelos, F. M. Mazzoni, A. J. M. Cardoso, "Análise de avarias em rolamentos, utilizando algoritmos de inteligência artificial", *Brazilian Journal of Development*, vol. 7, n. 7, pp.28080-29093, 2021.
- [5] N. Apinantanapong e P. Nivesrangsan, "Application of Artificial Neural Networks to Fault Detection of Rolling Ball Bearing", 2021 6th International Conference on Business and Industrial Research (ICBIR), pp. 147-152, 2021, doi: 10.1109/ICBIR52339.2021.9465860.
- [6] C. Lessmeier, J. K. Kimotho, D. Zimmer, W. Sextro, "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", *European Conference of the Prognostics and Health Management Society, Bilbao (Spain)*, 2016. URL: <https://mb.uni-paderborn.de/kat/forschung/datacenter/bearing-datacenter>.
- [7] Y. Jiang, et al. (2022). "Comparative Study of Fault Diagnosis in Permanent Magnet Synchronous Motors Using Vibration and Current Signals Based on Ensemble Learning Methods." *IEEE Transactions on Industrial*.
- [8] B. Johnson, et al. (2022). "Comparative Analysis of Current and Vibration Signals for Early Detection of Rolling Bearing Faults". *Mechanical Systems and Signal Processing*, 174, 108213.
- [9] X. Li, et al. (2022). "Comparative Study of Current and Vibration Signals for Rolling Bearing Fault Diagnosis using Deep Learning". *IEEE Access*, 10, 4109-4121.
- [10] X. Li, Z. Wang, e J. Zhang (2021). "Bearing fault diagnosis using random forests". *IEEE Access*, 9, 121963-121975.
- [11] Y. Wang, J. Zhang, X. Li, e M. Zhong (2021). "Bearing fault diagnosis using deep neural networks. *Sensors*", 21(1), 244. <https://www.mdpi.com/1424-8220/21/1/244>
- [12] Y. Zhang, X. Li, e Y. Zhang (2022). "Rolling bearing fault diagnosis using K-nearest neighbors and discrete wavelet transform". *IEEE Access*, 10, 4109-4121.
- [13] J. Wang, Z. Li, and J. Zhang (2022). "A Deep Learning Approach for Remaining Useful Life Prediction of Rolling Bearings Based on SKF Dataset". *IEEE Access*, 2022, 10, 4109-4121.
- [14] A. Kumar, A. Yadav, e V. Singh (2022). "Decision Tree-Based Bearing Fault Diagnosis Using Electric Current Signals". *Journal of Computational Science*, 58, 101534.
- [15] X. Li, Z. Wang, e J. Zhang, (2022). "Decision Tree Regression for Bearing Remaining Useful Life Prediction Using Electric Current Signals". *IEEE Access*, 10, 4109-4121.
- [16] Zhang, H., et al., "A Comparative Study of Vibration and Current Signals for Fault Diagnosis in Switched Reluctance Motors." *IEEE Transactions on Industrial Electronics*, 69(6), 4829-4839, 2022.
- [17] Pineda-Sanchez, M., Puche-Panadero, R., Riera-Guasp, M., Pérez-Cruz, J., Roger-Folch, J., Antonino-Daviu, J. A. (2019). Wavelet-based fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 129, 355-376.
- [18] Smith M., J. J. B. B. G. G. . B. B. A new wavelet basis for signal analysis. *IEEE Signal Processing Letters*, n. 30, p. 440-443, 2023
- [19] Wang, C., Zhang, Y., Zhang, H. (2023). Fault diagnosis of rotating machinery using multifractal statistical features. *Journal of Sound and Vibration*, 408, 115581.
- [20] Matlab. URL: <https://www.mathworks.com>
- [21] Kumar, A., Sathujoda, G., Bhalla, A. (2023). A review on vibration monitoring techniques for predictive maintenance of rotating machinery. *Journal of Vibration and Acoustics, Transactions of the ASME*, 145(1), 011005.
- [22] Kocak, H., Demir, A., Akbas, C. (2022). Vibration quantity share of multiple faults with similar frequency spectrum characteristics in rotational machinery. *Mechanical Systems and Signal Processing*, 168, 107682.