

Detecção de Falhas em Rolamentos de Motor usando Descritores em Sub-Bandas e Modelos de Aprendizado de Baixo Custo Computacional

Jean L. C. do Rosário, Bruno C. Bispo, Márcio H. Costa, e Diego M. do Carmo

Resumo—Este trabalho investiga a detecção de falhas em rolamentos de um motor elétrico, utilizando modelos de aprendizado de máquina de baixo custo computacional. Expandindo um estudo anterior, são incorporados descritores extraídos da banda completa e de sub-bandas de sinais de aceleração, velocidade e deslocamento, baseados na expertise técnica de analistas de sinais de vibração. A otimização individual dos detectores alcançou acurácias médias de 77,8% no rolamento do lado do acoplamento (DE) e de 84,2% no do lado oposto ao acoplamento (FE). Em relação ao trabalho anterior, o qual não impôs restrição mínima de especificidade nem removeu a componente contínua dos sinais de aceleração, esses resultados representam um ganho de 3,8 pontos percentuais no DE e uma redução de 7,8 pontos no FE. Na otimização conjunta, sob compartilhamento de modelo e descritores, as acurácias foram de 75,1% no DE e 77,8% no FE. Os resultados indicam que os descritores adicionados constituem um caminho promissor para a detecção eficiente de falhas em rolamentos, enquanto a degradação observada na otimização conjunta sugere uma capacidade de generalização moderada dos descritores para diferentes rolamentos de um mesmo motor.

Palavras-Chave—Rolamentos, detecção de falhas, descritores em sub-bandas, aprendizado de máquina, CWRU.

Abstract—This work investigates bearing fault detection in an electric motor using low-computational-cost machine learning models. Expanding upon a prior study, feature descriptors extracted from full-band and sub-band acceleration, velocity, and displacement signals are incorporated, based on the technical expertise of vibration analysts. Individual detector optimization achieved average accuracies of 77.8% for the drive-end (DE) bearing and 84.2% for the fan-end (FE) bearing. Compared to the previous work, which neither imposed a minimum specificity constraint nor removed the DC component from acceleration signals, these results represent a 3.8 percentage point gain for DE and a 7.8 percentage point reduction for FE. Under joint optimization, with shared model and features, accuracies were 75.1% for DE and 77.8% for FE. The results indicate that the added features constitute a promising approach for efficient bearing fault detection, while the performance degradation observed in the joint optimization suggests a moderate generalization capability of the features across different bearings of the same motor.

Keywords—Bearings, fault detection, subband features, machine learning, CWRU.

I. INTRODUÇÃO

Os rolamentos são componentes numerosos em máquinas rotativas que, por estarem frequentemente submetidos a condições operacionais severas como altas velocidades, cargas elevadas e escassez de lubrificação, são suscetíveis a danos e

ao desgaste prematuro [1]. Essas falhas podem levar à interrupção de processos industriais, perdas econômicas significativas e, em casos extremos, a acidentes [2]. Portanto, a detecção precoce de falhas em rolamentos é essencial para manter a integridade e a continuidade operacional de tais sistemas.

A análise de sinais de vibração é uma das abordagens mais eficazes para monitorar a condição de rolamentos, permitindo a detecção de anomalias durante a operação do equipamento. No entanto, o crescente volume de dados, provenientes de múltiplos sensores instalados em múltiplas máquinas, tornou o processo de análise não-automatizada inviável. Métodos de detecção baseados em aprendizado de máquina (ML, do inglês *machine learning*) têm se mostrado uma alternativa promissora [3], mas requerem uma grande quantidade de dados de vibração coletados sob diferentes condições de operação.

A base de dados da Case Western Reserve University (CWRU) tem sido amplamente utilizada para desenvolver detectores e classificadores de falhas em rolamentos, como por exemplo em [3], [4], [5], [6]. Os estudos iniciais separavam os dados em conjuntos de treinamento e teste com base na carga do motor [3]. No entanto, essa divisão causa vazamento de dados uma vez que sinais obtidos com os mesmos rolamentos instalados na máquina são usados em ambos os conjuntos [3], levando a modelos com desempenho superestimado [3], [7].

Para evitar, ou pelo menos reduzir, o vazamento de dados no desenvolvimento de classificadores de falhas em rolamentos, uma divisão dos sinais do banco CWRU com base no tamanho da falha foi proposta em [3]. Um classificador ResNet, utilizando espectrogramas de segmentos dos sinais de vibração como entrada e validação cruzada 3-fold, foi avaliado. Uma acurácia média de 53,1% foi obtida, muito inferior aos 95% alcançado pelo mesmo modelo com os dados divididos pela carga do motor [3], demonstrando tanto o desafio de classificar eficazmente as falhas em rolamentos quanto a superestimação dos resultados causada pelo vazamento de dados.

Recentemente, uma divisão dos sinais de vibração da CWRU, também com base no tamanho da falha, foi proposta em [8] para o desenvolvimento de detectores de falhas em rolamentos. Detectores locais — um para o lado do acoplamento do motor (DE, do inglês *drive-end*), outro para o lado oposto ao acoplamento (FE, do inglês *fan-end*) — utilizando sete descritores em banda completa e modelos clássicos de ML foram avaliados usando validação cruzada 3-fold. Acurácias médias de 74% e 92% foram obtidas no DE e FE, respectivamente, enquanto 87% e 85% foram obtidas com uma CNN, indicando que é possível detectar falhas em rolamentos usando modelos de ML com baixo custo computacional [8].

O presente estudo tem como objetivo estender [8] ao

Jean L. C. do Rosário, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis-SC. Bruno C. Bispo e Márcio H. Costa, Departamento de Engenharia Elétrica e Eletrônica, Universidade Federal de Santa Catarina, Florianópolis-SC. Diego M. do Carmo, Dynamox, Florianópolis-SC. E-mails: jean.rosario@posgrad.ufsc.br, {bruno.bispo, marcio.costa}@ufsc.br, diego.carmo@dynamox.net.

adicionar descritores em banda completa e descritores em sub-bandas, extraídos não somente dos sinais de aceleração como também de sinais de velocidade e deslocamento, para desenvolver um detector de falhas no rolamento do DE e um no rolamento do FE, utilizando a base de dados CWRU. Este artigo está organizado da seguinte forma: a Seção II descreve a metodologia adotada, incluindo a base de dados, o processamento dos sinais, a engenharia de descritores, e o processo de treinamento dos modelos; a Seção III apresenta e discute os resultados obtidos; a Seção IV conclui o estudo.

II. METODOLOGIA

Essa seção descreve a metodologia adotada no desenvolvimento de detectores de falhas em rolamentos de um motor, um para o rolamento do DE e outro para o rolamento do FE.

A. Base de Dados

1) *Descrição*: A base de dados CWRU contém sinais de aceleração adquiridos em uma bancada de testes composta por um motor elétrico Reliance de 2 HP, um transdutor de torque, um dinamômetro e eletrônica de controle [9]. Os rolamentos de teste suportam o eixo do motor [9].

Os sinais de vibração foram coletados utilizando acelerômetros fixados à carcaça do motor na posição de 12 horas, tanto no DE quanto no FE, para cargas de motor de 0, 1, 2 e 3 HP, correspondendo a velocidades entre 1797 e 1720 RPM [9].

Os rolamentos de teste eram do tipo rígidos de uma carreira de esferas. Para cada extremidade do motor, além de um rolamento saudável, foram utilizados rolamentos com falhas pontuais nas regiões da esfera (B, do inglês *ball*), pista interna (IR, do inglês *inner race*) e pista externa (OR, do inglês *outer race*), com diâmetros de 0,007, 0,014, 0,021, 0,024 e 0,040 polegadas [9]. As falhas de OR foram introduzidas de modo a estarem localizadas nas posições de 3, 6 ou 12 horas [9].

Os sinais possuem aproximadamente 10 s de duração e são organizados em quatro categorias com base na taxa de amostragem e na falha do rolamento. A categoria Baseline 48k contém sinais com taxa de amostragem de 48 kHz quando ambos os rolamentos estão saudáveis [9]. As categorias DE Bearing 12k e DE Bearing 48k contêm sinais com taxa de amostragem de 12 e 48 kHz, respectivamente, quando há uma falha no rolamento do DE, mas não no rolamento do FE [9]. A categoria FE Bearing 12k contém sinais com taxa de amostragem de 12 kHz quando há uma falha no rolamento do FE, mas não no rolamento do DE [9]. Nenhum sinal é capturado com falhas em ambos os rolamentos simultaneamente.

2) *Divisão*: Neste trabalho, como em [8], foram utilizados os sinais de aceleração da base CWRU pertencentes às categorias Baseline 48k, DE Bearing 12k e FE Bearing 12k, coletados sem falhas, com falha no rolamento do DE ou do FE, falhas dos tipos IR, OR e B, falhas e de tamanhos 0,007, 0,014 e 0,021 polegadas, e sob cargas de 1, 2 e 3 HP.

Esses sinais foram divididos em conjunto de treinamento e teste conforme proposto em [8]. Os sinais capturados quando ambos os rolamentos estão saudáveis foram destinados exclusivamente ao conjunto de teste. Os demais sinais selecionados foram divididos com base no tamanho da falha, considerando que os modelos de ML serão treinados e avaliados utilizando uma validação cruzada do tipo 3-fold.

TABELA I
DIVISÃO DOS SINAIS NO FOLD 1 DO DETECTOR DO DE.

Classe	Conjunto de Treinamento		Conjunto de Teste
Defeituosa	(DI7/FH) _{1,2,3}	(DI14/FH) _{1,2,3}	(DI21/FH) _{1,2,3}
	(DB7/FH) _{1,2,3}	(DB14/FH) _{1,2,3}	(DB21/FH) _{1,2,3}
	(DO7/FH) _{1,2,3}	(DO14/FH) _{1,2,3}	(DO21/FH) _{1,2,3}
Saudável	(DH/FI7) _{1,2,3}	(DH/FI14) _{1,2,3}	(DH/FI21) _{1,2,3}
	(DH/FB7) _{1,2,3}	(DH/FB14) _{1,2,3}	(DH/FB21) _{1,2,3}
	(DH/FO7) _{1,2,3}	(DH/FO14) _{1,2,3}	(DH/FO21) _{1,2,3}
			(DH/FH) _{1,2,3}

A rotulagem e a divisão dos sinais em conjuntos de treinamento e teste para o primeiro fold do detector do DE são mostrados na Tabela I. Os sinais adquiridos no DE são denotados por $(DAX/FBY)_k$, onde D significa DE, $A = \{H, I, O, B\}$ é o estado de saúde (saudável, falha em IR, falha em OR ou falha em B) do rolamento no DE, $X = \{7, 14, 21\}$ é o tamanho da falha em mils do rolamento no DE, F indica FE, $B = \{H, I, O, B\}$ é o estado de saúde do rolamento no FE, $Y = \{7, 14, 21\}$ é o tamanho da falha em mils do rolamento no FE, e $k = \{1, 2, 3\}$ é a carga do motor em HP. Um esquema semelhante é aplicado aos outros dois folds. Os sinais adquiridos no FE são denotados por $(FBY/DAX)_k$ e esquemas similares para sua divisão em conjuntos de treinamento e teste são obtidos.

O fator crucial para essa proposta de divisão foi uma análise experimental mostrando que, nos sinais $(DH/FIY)_k$, $(DH/FOY)_k$ e $(DH/FBY)_k$, a possível assinatura do rolamento saudável do DE é mascarada pelo defeito no rolamento do FE. O mesmo ocorre nos sinais adquiridos no FE. Isso permite rotular esses sinais como a classe saudável no desenvolvimento de detectores de falhas locais, sem o receio de comprometer a aprendizagem por causa de vazamento de dados [8].

B. Processamento dos Sinais

Os sinais da categoria Baseline 48k foram reamostrados para 12 kHz. Diferentemente de [8], a componente contínua foi removida via subtração da média temporal para mitigar eventual *offset* dos sensores. Estendendo [8], sinais de velocidade e de deslocamento foram gerados. A velocidade foi produzida por meio da acumulação da aceleração. De forma análoga, o deslocamento foi obtido ao subtrair a média temporal e em seguida aplicar a operação de acumulação à velocidade.

Os sinais de aceleração e de velocidade foram então filtrados, usando filtros Butterworth de ordem seis, para conter exclusivamente faixas específicas do espectro de frequência. Foram gerados cinco sinais de aceleração passa-faixa filtrados e quatro sinais de aceleração passa-alta filtrados. As faixas de passagem foram 1–3 kHz, 3–6 kHz, 1–2,5 kHz, 1–6 kHz, 0,5–5 kHz, 0,8–2 kHz, 1–6 kHz, 2–6 kHz e 0,5–6 kHz. Um sinal de velocidade passa-faixa filtrado em 1–2,5 kHz foi gerado.

Os sinais de aceleração nas faixas de 0,5–6 kHz, 0,5–5 kHz, 0,8–2 kHz, 1–6 kHz e 2–6 kHz tiveram seus envelopes calculados usando um filtro de Hilbert com 300 amostras. Cada envelope foi então submetido ao processo de janelamento. Os demais sinais foram diretamente submetidos ao janelamento.

O processo de janelamento, assim como em [8], consistiu em dividir os sinais em segmentos com duração de duas rotações completas (entre 802 ou 836 amostras, dependendo do RPM) e com 50% de sobreposição, usando uma janela

retangular. A maioria dos segmentos foi enviada diretamente ao processo de extração de descritores, outros passaram antes por mais uma etapa de processamento.

Os segmentos do sinal de velocidade em banda completa e do envelope do sinal de aceleração na faixa 0,5–6 kHz tiveram seu espectro de magnitude obtido via transformada rápida de Fourier (FFT) com 8192 pontos. Os segmentos da aceleração em banda completa tiveram seu cepstro obtido como

$$\tilde{x}(n) = \text{FFT}\{10 \log_{10}[|\text{FFT}\{x(n)\}|^2]\}, \quad (1)$$

onde $x(n)$ e $\text{FFT}\{\cdot\}$ denotam um segmento e o operador FFT.

As etapas de processamento e as faixas de frequência foram sugeridas por analistas profissionais de sinais de vibração.

C. Engenharia de Descritores

O fluxo dessa etapa começou com a extração dos descritores. Na sequência, para cada fold, eles foram normalizados em relação à população de referência. Por fim, considerando os três folds, um método de seleção foi empregado para isolar subconjuntos mais discriminativos de descritores.

1) *Extração*: Um total de 20 descritores em banda completa e 25 descritores em sub-bandas foram extraídos. Todos foram sugeridos por analistas profissionais de sinais de vibração.

Dos segmentos do sinal de aceleração em banda completa, foram extraídos: média, desvio padrão, valor de pico (VP), valor pico a pico (PP), curtose, RMS (do inglês *root mean square*), assimetria, fator de crista, fator de forma, valor do pico espectral, pico cepstral na quefrência correspondente a $1 \times \text{BPFI}$ (do inglês *ball pass frequency – inner race*), valor do pico cepstral na quefrência $1 \times \text{BPFO}$ (do inglês *ball pass frequency – outer race*), valor do pico cepstral em $1 \times \text{FTF}$ (do inglês *fundamental train frequency*), e valor do pico cepstral em $1 \times \text{BSF}$ (do inglês *ball spin frequency*).

De cada segmento dos sinais de aceleração nas faixas de 1–3 kHz e 3–6 kHz, foi extraído o RMS. Dos segmentos de aceleração nas faixas de 1–2,5 kHz e 1–6 kHz, foi extraído o PP. Dos segmentos de envelope dos sinais de aceleração nas bandas de 0,5–5 kHz e 1–6 kHz, foram extraídos o PP e RMS. Dos segmentos de envelope dos sinais de aceleração nas faixas de 0,8–2 kHz e 2–6 kHz foi extraído apenas o PP.

De cada segmento do sinal de aceleração na faixa de 0,5–6 kHz, foram extraídos os valores de pico espectral nas frequências correspondentes à $0,5 \times \text{RPM}$, $1 \times \text{RPM}$, $1 \times \text{BPFI}$, $2 \times \text{BPFI}$, $3 \times \text{BPFI}$, $1 \times \text{BPFO}$, $2 \times \text{BPFO}$, $3 \times \text{BPFO}$, $1 \times \text{BSF}$, $2 \times \text{BSF}$, $3 \times \text{BSF}$, $1 \times \text{FTF}$, $2 \times \text{FTF}$, e $3 \times \text{FTF}$.

De cada segmento do sinal de velocidade em banda completa, foram extraídos o PP, RMS, pico espectral, e pico espectral na frequência correspondente a $1 \times \text{RPM}$. Dos segmentos do sinal de deslocamento, foram extraídos o RMS e PP.

Um resumo dos descritores empregados, e das correspondentes faixas de frequência, são mostrados na Tabela II.

2) *Normalização*: Uma estratégia de normalização dos descritores foi realizada empregando o método de z-score. Esse processo foi conduzido independentemente para cada fold da validação, utilizando a população de referência específica. Para um fold, o i -ésimo valor do j -ésimo descritor, denotado por x_{ij} , $1 \leq j \leq 45$, foi transformado da seguinte forma

$$\tilde{x}_{ij} = [x_{ij} - \mu_j] / \sigma_j, \quad (2)$$

TABELA II
DESCRITORES E SUAS FAIXAS DE FREQUÊNCIAS.

Sinal	Banda	Domínio	Descritor	Numeração
Ace.	Completa	Tempo	Média	1
			Desvio padrão	2
			RMS	3
			Valor de pico	4
			Pico a pico	5
			Assimetria	6
			Curtose	7
			Fator de crista	8
		Fator de forma	9	
		Frequência	Valor de pico	10
		Cepstro	Pico 1×BPFI	11
			Pico 1×BPFO	12
			Pico 1×FTF	13
			Pico 1×BSF	14
	1–3 kHz 3–6 kHz 1–2,5 kHz 1–6 kHz	Tempo	RMS	15
			RMS	16
			Pico a pico	17
			Pico a pico	18
	0,5–5 kHz	Envelope Temporal	RMS	19
			Pico a pico	20
	1–6 kHz		RMS	21
			Pico a pico	22
	0,8–2 kHz 2–6 kHz		Pico a pico	23
			Pico a pico	24
	0,5–6 kHz	Espectro do Envelope Temporal	Pico 0,5×RPM	25
			Pico 1×RPM	26
			Pico 1×BPFI	27
			Pico 2×BPFI	28
			Pico 3×BPFI	29
			Pico 1×BPFO	30
			Pico 2×BPFO	31
			Pico 3×BPFO	32
			Pico 1×BSF	33
			Pico 2×BSF	34
			Pico 3×BSF	35
			Pico 1×FTF	36
			Pico 2×FTF	37
			Pico 3×FTF	38
Vel.	Completa	Tempo	RMS	39
			Pico a pico	40
	1–2,5 kHz	Frequência	Valor de pico	41
			Pico 1×RPM	42
Des.	Completa	Tempo	RMS	43
			RMS	44
			Pico a pico	45

onde μ_j e σ_j são a média e o desvio padrão do j -ésimo descritor, calculados sobre a população específica do fold.

3) *Seleção*: Com o objetivo de reduzir a dimensionalidade dos dados e tentar aprimorar o desempenho da detecção de falhas, um método de seleção baseado em filtro foi empregado para identificar os descritores com maior poder de discriminação. Esse processo foi conduzido independentemente para cada combinação de rolamento e modelo de ML.

Em cada combinação, todos os descritores foram empregados individualmente para treinamento e teste dos três folds. Na estratégia de otimização por sensor, foram selecionados os quinze descritores com os maiores valores médios de acurácia em cada extremidade do motor. Na estratégia de otimização por máquina, foram selecionados os sete descritores com os maiores valores médios de acurácia no DE e os oito descritores com os maiores valores médios de acurácia no FE.

A quantidade de quinze descritores selecionados foi definida de forma a manter baixo o custo computacional dos modelos,

enquanto a quantidade por sensor foi escolhida devido a maior dificuldade de detecção no DE, como será mostrado a frente.

D. Processo de Classificação

Como [8], o presente trabalho optou por desenvolver detectores locais de falhas, um para o rolamento do DE e outro para o rolamento do FE, visto que o banco CWRU fornece sinais adquiridos de ambas as extremidades do motor. Essa estratégia permite que cada detector seja implementado individualmente usando apenas os sinais adquiridos no respectivo rolamento.

1) *Modelos de Aprendizado*: Os detectores foram desenvolvidos na plataforma MATLAB. Os modelos de ML avaliados foram máquina de vetores de suporte (SVM, do inglês *support vector machine*), análise discriminante quadrática (QDA, do inglês *quadratic discriminant analysis*) e árvore de decisão (DT, do inglês *decision tree*). Uma descrição detalhada desses modelos pode ser encontrada em [10]. Todos os modelos foram avaliados usando validação cruzada 3-fold, como em [8].

O SVM foi implementado usando a função “fitcsv”, com kernel gaussiano, “box constraint = 1” e os demais parâmetros com valores padrão. O QDA foi implementado usando a função “fitcdiscr”, com “discrimtype = quadratic” e os demais parâmetros com valores padrão. A árvore de decisão foi implementada usando a função “fitctree”, com o critério de impureza de Gini, 29 nós, uma profundidade máxima de 5, e os outros parâmetros com valores padrão.

2) *Estratégias de Otimização*: Duas estratégias de otimização dos modelos foram aplicadas. Na primeira, denominada por sensor, os dois detectores foram implementados de maneira independente, explorando todas as combinações dos quinze descritores selecionados em cada modelo de ML, com o objetivo de avaliar o teto de desempenho em cada rolamento.

Na segunda, denominada otimização por máquina, os dois detectores compartilharam o mesmo modelo de ML e a mesma combinação dos descritores selecionados. Ressalta-se, contudo, que cada detector foi treinado e testado separadamente. O objetivo desta estratégia foi avaliar a capacidade de generalização dos descritores para diferentes rolamentos.

Em ambas as estratégias, estabeleceu-se como critério de seleção apenas os modelos que atingiram ES1 não inferior a 99%. Essa restrição, não aplicada em [8], justifica-se pelo fato de que o estado saudável, com todos os rolamentos íntegros, é a condição de operação predominante no cotidiano industrial.

3) *Métricas de Avaliação*: Os detectores foram avaliados por meio da média e do desvio padrão da acurácia (AC), sensibilidade (SE), especificidade (ES) e F1-score (F1), calculados ao longo dos folds. Medidas específicas de ES, considerando apenas os sinais adquiridos quando ambos os rolamentos estão saudáveis (ES1) e quando o rolamento na outra extremidade do motor é defeituoso (ES2), também foram calculadas.

III. RESULTADOS E DISCUSSÃO

Essa seção apresenta e discute os resultados obtidos na detecção de falhas nos rolamentos do DE e FE do motor, considerando os três folds da validação cruzada.

A. Otimização por Sensor

As Tabelas III e IV apresentam os melhores resultados da detecção de falhas no rolamento do DE e do FE, respectivamente, obtidos com cada modelo de ML e utilizando a

TABELA III
MELHORES RESULTADOS (%) DA DETECÇÃO DE FALHAS NO DE.

Modelo	Descritores	AC	F1	SE	ES	ES1	ES2
SVM	7,17,21,25,28, 32,34,40,43	77,8 ± 9,0	75,8 ± 7,9	79,0 ± 10,1	76,8 ± 19,2	99,7	98,2
	7,17,21,25, 32,40,43	77,0 ± 8,4	74,5 ± 7,6	76,8 ± 13,0	77,2 ± 19,5	99,5	99,1
QDA	7	74,2 ± 1,8	63,5 ± 8,8	55,9 ± 23,1	87,9 ± 17,5	100	99,8
	2,3,4,5,10, 17,19,20,27,34	74,1 ± 18,0	73,6 ± 12,3	77,3 ± 9,0	71,7 ± 34,5	99,8	87,7
DT	7,32	73,3 ± 5,9	68,7 ± 8,4	69,3 ± 13,1	76,4 ± 9,3	99,1	80,4
	5,20,25,28, 30,31,32,35	73,0 ± 18,5	70,3 ± 18,1	71,1 ± 13,8	74,5 ± 22,2	100	88,5

estratégia de otimização por sensor. Ressalta-se a restrição imposta de $ES1 \geq 99\%$. São exibidos a numeração dos descritores utilizados, a média e o desvio padrão de AC, F1, SE e ES, assim como os valores médios de ES1 e ES2.

No DE, a maior AC foi de 77,8%, obtida com o SVM e um conjunto de nove descritores: curtose da aceleração em banda completa, PP da aceleração na faixa 1–2,5 kHz, RMS do envelope da aceleração na faixa 1–6 kHz, picos espectrais nas frequências $0,5 \times \text{RPM}$, $2 \times \text{BPFI}$, $3 \times \text{BPFO}$ e $2 \times \text{BSF}$ do envelope da aceleração na faixa 0,5–6 kHz, PP da velocidade em banda completa, RMS da velocidade na faixa 1–2,5 kHz. Removendo dois destes descritores, há uma redução de apenas 0,8 pontos percentuais na média da AC. Isso sugere que o desempenho não decorre do aumento de dimensionalidade, mas da escolha de descritores que contenham informação relevante sobre o defeito do rolamento. Além disso, essas configurações alcançaram médias superiores a 74% em todas as métricas, indicando desempenhos equilibrados.

Os modelos QDA e DT destacaram-se por alcançar suas maiores ACs com poucos descritores. O QDA obteve AC média de 74,2% utilizando apenas um descritor, enquanto o DT alcançou 73,3% com dois. Contudo, o QDA apresentou elevada disparidade entre SE (55,9%) e ES (87,9%), evidenciando maior dificuldade em detectar as falhas no rolamento, comportamento também reportado em [8]. O equilíbrio no desempenho do QDA é estabelecido com um aumento significativo de descritores, embora à custa de maior dispersão nos resultados. Cabe ressaltar, porém, o elevado desvio padrão observado em todas as métricas para todos os modelos de ML, indicando alta variabilidade de desempenho ao longo dos *folds*.

No FE, obtiveram-se taxas de detecção mais elevadas com quantidades semelhantes de descritores. A maior AC foi de 84,2%, obtida com SVM e nove descritores: média da aceleração em banda completa, RMS da aceleração na faixa 3–6 kHz, PP do envelope temporal da aceleração na faixa 2–6 kHz, picos espectrais nas frequências $3 \times \text{BPFO}$ e $2 \times \text{BSF}$ do envelope da aceleração na faixa 0,5–6 kHz, RMS da velocidade em banda completa, VP do espectro da velocidade em banda completa, RMS e PP do deslocamento em banda completa. Uma redução para quatro descritores acarreta uma perda de 2,4 pontos percentuais na AC, reforçando que o desempenho decorre da seleção criteriosa e não do volume de descritores. Novamente, o QDA obteve suas maiores ACs com poucos descritores, 84% com dois e 81,2% com apenas um, porém mantendo um SE consideravelmente inferior aos outros modelos.

Em comparação a [8], as ACs médias obtidas são 3,8 pontos

TABELA IV

MELHORES RESULTADOS (%) DA DETECÇÃO DE FALHAS NO FE.

Modelo	Descritores	AC	F1	SE	ES	ES1	ES2
SVM	1,16,24,32,34,39,41,44,45	84,2 ± 4,4	81,0 ± 3,3	78,1 ± 8,6	88,8 ± 12,8	99,2	97,0
	16,27,34,39	81,8 ± 3,5	79,7 ± 2,8	83,5 ± 8,1	80,5 ± 10,3	99,6	78,3
QDA	27,34	84,0 ± 10,3	79,8 ± 12,5	73,8 ± 11,3	91,6 ± 10,5	100	73,0
	34	81,2 ± 2,4	75,0 ± 1,3	65,8 ± 3,8	92,6 ± 7,0	100	80,9
DT	1,21,28,31,36,44	80,1 ± 6,1	77,0 ± 7,7	78,5 ± 9,7	81,3 ± 4,5	99,3	82,2
	1,21,32,36,44	79,4 ± 6,0	75,5 ± 7,5	74,5 ± 8,5	83,1 ± 4,4	100	84,3

percentuais superiores no DE, mas 7,8 pontos inferiores no FE. Ressalta-se, contudo, que [8] não aplicou a restrição de $ES1 \geq 99\%$ nem removeu a componente contínua nos sinais de aceleração. Sem essa remoção, a abordagem proposta no presente estudo alcança ACs médias de 79,5% no DE e 99,9% no FE, resultado que sugere a presença de elevado *offset* nos sinais da base CWRU, sobretudo no sensor FE.

B. Otimização por Máquina

A Tabela V apresenta os melhores resultados da detecção de falhas no rolamento do DE e do FE, respectivamente, obtidos com cada modelo de ML e utilizando a estratégia de otimização por máquina. Ressalta-se a restrição imposta de $ES1 \geq 99\%$. São exibidos a numeração dos descritores, a média e o desvio padrão de AC, e o valor médio de ES1.

O melhor desempenho combinado apresentou ACs médias de 75,1% no DE e 77,8% no FE, obtidas com o SVM e dez descritores. Uma AC 5 pontos percentuais superior no FE foi alcançada com QDA e apenas três descritores, porém ao custo de uma redução de 3,9 pontos no DE, representando uma solução menos equilibrada, mas de menor custo computacional. O DT, por outro lado, obteve ACs inferiores a 68% em sua configuração mais balanceada entre os sensores DE e FE.

Esses resultados representam uma redução de 2,7 e 6,4 pontos percentuais nos valores médios de AC obtidos com a otimização por sensor, indicando uma moderada capacidade de generalização dos descritores para os dois rolamentos. Ressalta-se que os modelos de ML foram treinados separadamente para cada extremidade do motor. Testes com uma maior variedade de sinais de aceleração, adquiridos de outros modelos de rolamentos, de rolamentos de outros motores e de rolamentos de outras máquinas rotativas, são necessários para confirmar a capacidade de generalização da metodologia.

IV. CONCLUSÃO

Este trabalho investigou a detecção local de falhas em rolamentos de um motor elétrico, utilizando modelos de ML com baixo custo computacional. Estendendo um estudo anterior, foram incorporados descritores em banda completa e descritores em sub-bandas, extraídos não somente dos sinais de aceleração como também de sinais de velocidade e deslocamento.

Ao otimizar os detectores individualmente, acurácias médias de 77,8% e 84,2% foram obtidas nos rolamentos do DE e FE, respectivamente. Esse desempenho representa um incremento de 3,8 pontos percentuais no DE e uma redução de 7,8 pontos no FE em relação aos resultados reportados em [8], os quais

TABELA V

MELHORES RESULTADOS (%) DA DETECÇÃO OTIMIZADA POR MÁQUINA.

Modelo	Descritores	Rolamento DE		Rolamento FE	
		AC	ES1	AC	ES1
SVM	7,8,17,21,27,28,32,39,40,45	75,1 ± 10,8	99,1	77,8 ± 4,0	99,1
	7,8,17,21,27,35,39,40,45	74,1 ± 9,3	99,8	78,7 ± 4,0	99,2
QDA	20,27,28,32,36,44,45	73,1 ± 19,7	99,7	77,7 ± 8,4	99,1
	27,34,36	71,2 ± 18,7	100	82,8 ± 10,3	100
DT	5,8,27,31,32,35,36	67,5 ± 11,4	100	65,6 ± 13,5	99,8
	5,20,28,31,35,36,44	63,5 ± 7,2	99,1	73,8 ± 9,6	99,7

foram obtidos sem a remoção da componente contínua nos sinais de aceleração e sem a restrição imposta à especificidade. Em cenário de compartilhamento de modelo e descritores, acurácias de 75,1% e 77,8% foram obtidas no DE e FE.

Os resultados indicam que os descritores adicionados constituem um caminho promissor para detectar falhas em rolamentos com baixo custo computacional. A degradação de desempenho observada na otimização conjunta sugere uma capacidade de generalização moderada dos descritores para diferentes rolamentos de um mesmo motor. Testes com uma maior variedade de sinais de aceleração são necessários para confirmar a capacidade de generalização da metodologia.

REFERÊNCIAS

- [1] R. Liu, B. Yang, X. Zhang, S. Wang e X. Chen, "Time-frequency atoms-driven support vector machine method for bearings incipient fault diagnosis," *Mechanical Systems and Signal Processing*, vol. 75, no. 1, pp. 345–370, 2016.
- [2] T. Duan, Z. Liao, T. Li, H. Tang e P. Chen, "Bearing fault diagnosis based on state-space principal component tracking filter algorithm," *IEEE Access*, vol. 8, pp. 158 784–158 795, 2021.
- [3] J. Hendriks, P. Dumond e D. A. Knox, "Towards better benchmarking using the CWRU bearing fault dataset," *Mechanical Systems and Signal Processing*, vol. 169, p. 108732, 2022.
- [4] D. Neupane e J. Seok, "Bearing fault detection and diagnosis using Case Western Reserve University dataset with deep learning approaches: a review," *IEEE Access*, vol. 8, pp. 93 155–93 178, 2020.
- [5] W. A. Smith e R. B. Randall, "Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study," *Mechanical Systems and Signal Processing*, vol. 64–65, pp. 100–131, 2015.
- [6] S. Maurya, V. Singh e N. K. Verma, "Condition monitoring of machines using fused features from EMD-based local energy with DNN," *IEEE Sensors Journal*, vol. 20, no. 15, pp. 8316–8327, 2020.
- [7] H. Abburi, T. Chaudhary, S. H. W. Ilyas, L. Manne, D. Mittal, D. Williams, D. Snidauf, E. Bowen e B. Veeramani, "A closer look at bearing fault classification approaches," em *Annual Conference of the PHM Society*, vol. 15, no. 1, 2023.
- [8] K. da Rocha, V. F. Filho, B. C. Bispo, M. H. Costa, D. M. do Carmo e D. Braga, "Local detection with low computational cost of faults in rotating machine bearings," em *International Symposium on Internet of Things*, Campinas, Brasil, Out. 2025, pp. 1–4.
- [9] Case Western Reserve University Bearing Data Center, "Bearing Data Center," <https://engineering.case.edu/bearingdatacenter>, acessado em 6 Maio 2026.
- [10] G. James, D. Witten, T. Hastie e R. Tibshirani, *An Introduction to Statistical Learning: With Application in R*, 2a ed. New York, NY: Springer, 2021.