

# Analysis of Window Size and Statistical Features for SVM-based Fault Diagnosis in Bearings

Jusley S. Souza, Marcus V. L. dos Santos, Rafael S. Bayma and Alexandre L. A. Mesquita

**Abstract**—Bearings are mechanical components used in many rotating devices. They exhibit high failure rates which cause significant maintenance downtime. For this reason, there has been an increase in the efforts for designing techniques that allow early failure detection. Fault diagnosis systems based on machine learning are becoming increasingly prominent in this scenario. These techniques have three fundamental steps: signal acquisition, feature extraction and fault classification. The present work provides a detailed analysis for the second and third steps, in order to propose systematic ways for computing efficient statistical features for bearing fault recognition using Support Vector Machine (SVM) classifiers. More specifically, the classifier's performance is studied by considering different statistical features computed under different number of signal samples. Results show that even a small set of statistical features can be used for designing high accuracy bearing fault detection systems provided such features are computed from an appropriately sized window.

**Index Terms**—Bearings, fault diagnostic, machine learning, SVM

## I. INTRODUÇÃO

EM sistemas industriais modernos, a integridade dos diversos componentes que constituem uma máquina é tão importante para o desempenho do processo quanto o bem estar da própria máquina. Os rolamentos, por exemplo, são comumente usados em máquinas rotativas e constituem a principal fonte de falhas nesses equipamentos [1]. Em motores de indução trifásicos, 51% das falhas são provenientes dos rolamentos [2]. As razões mais comuns pelas quais os defeitos surgem nestes componentes são procedimentos inadequados de montagem ou manutenção, lubrificação incorreta e erosão elétrica, que podem resultar em desgaste, corrosão ou trincas. Tais defeitos podem se desenvolver na pista externa, interna, nos elementos rolantes ou gaiola [3]. Estas falhas acarretam danos tanto ao componente quanto ao sistema, e podem ocasionar problemas físicos (quebra e inutilização de componentes) e financeiros (indisponibilidade do sistema na área produtiva).

Na busca por redução de custos, eficiência nas intervenções de manutenção mecânica e aumento da disponibilidade dos equipamentos, técnicas de manutenção e monitoramento vem sendo empregadas para minimizar e/ou eliminar tais problemas e gerar benefícios para a indústria [4]. O avanço em

tecnologias de aquisição de sinais, poder computacional e, em particular, técnicas de inteligência artificial e aprendizado de máquina (machine learning), têm possibilitado diagnósticos mais automatizados, auxiliando a intervenção de especialistas [2], [5], [6].

O paradigma de diagnóstico de falhas auxiliado por aprendizado de máquina pode ser dividido em três etapas: aquisição de dados, extração de características e reconhecimento (ou classificação) de padrões. Na primeira, sinais são coletados a partir de sensores instalados no equipamento, com o objetivo de obter informação quantitativa sobre seu estado. Neste contexto são comumente usados sinais de vibração, temperatura [7], corrente elétrica (principalmente para diagnóstico de falhas elétricas) [8], e acústicos [9], sendo os sinais de vibrações os mais usados para diagnóstico de falhas em rolamentos [10].

Na segunda etapa, o sinal coletado é processado no domínio do tempo, frequência ou tempo-frequência [1], [12], com o objetivo de extrair atributos (ou features) que possam representar o estado da máquina. Como exemplo de atributos tem-se indicadores estatísticos, coeficientes de modelos auto regressivos [13], entropia de sinais [14], decomposição em valores singulares [15], dentre outros [16]. Os atributos são reunidos em um vetor de baixa dimensão (bem menor que o número de amostras do sinal coletado), que é usado como entrada para a etapa seguinte, a de classificação.

Na terceira etapa, um algoritmo especializado em classificação de padrões faz a leitura dos atributos e emite o diagnóstico. Isso normalmente é feito após uma etapa de treinamento, onde o algoritmo é ajustado para reconhecer entre diferentes padrões de operação a partir de um histórico de funcionamento da máquina. Vários algoritmos têm sido usados para este fim no contexto de máquinas rotativas, tais como redes neurais artificiais [17], [5], k-Nearest Neighbors (k-NN) [18], classificador Naive Bayes [19] e Máquina de Vetores de Suporte (Support Vector Machine, SVM) [20], [21].

Atributos estatísticos no domínio do tempo, que incluem, por exemplo, média, variância, fator k, fator de crista, curtose e assimetria, têm sido utilizados no diagnóstico de máquinas com diferentes classificadores [2], [22], [23], [24], [25]. Neste sentido, a presente pesquisa visa contribuir para a melhoria do processamento do sinal de vibração objetivando a obtenção de atributos estatísticos mais significativos para o diagnóstico de falhas em rolamentos baseado em SVM. Mais especificamente, é verificada a influência do número de amostras do sinal na acurácia da classificação e a investigação de um conjunto mínimo de atributos para o diagnóstico de defeitos em rolamentos com diferentes graus de severidade.

O artigo está organizado na seguinte forma: a Seção II

J. S. Souza, Universidade Federal do Pará, Tucuruí, Pará, Brasil, souzabar-bju@gmail.com.

M. V. L. dos Santos, Universidade Federal do Pará, Parauapebas, Pará, Brasil, viniluz10@gmail.com.

R. S. Bayma, Universidade Federal do Pará, Tucuruí, Pará, Brasil, rafael-bayma@ufpa.br

A. L. A. Mesquita, Universidade Federal do Pará, Tucuruí, Pará, Brasil, alexmesq@ufpa.br

apresenta uma breve revisão dos atributos estatísticos usados no trabalho, assim como o método de classificação, as características dos defeitos nos rolamentos e a metodologia de aquisição e processamento dos sinais. Na seção III apresentam-se e discutem-se os resultados encontrados, e na seção IV são apresentadas as conclusões e recomendações para trabalhos futuros.

## II. MÉTODOS

### A. Atributos Estatísticos

Neste trabalho são usados como atributos de classificação os seguintes indicadores: valor RMS (root mean square), Fator de crista, Fator K, Curtose e Assimetria. Os três primeiros são comumente utilizados em análise de vibração [26], enquanto que os dois últimos são medidas estatísticas que permitem explorar a natureza estocástica dos sinais envolvidos.

Um dos atributos mais utilizados para investigação primária de integridade da máquina é o valor global RMS (root mean square), em que os níveis são medidos e comparados com valores tabelados para indicar a severidade do defeito [26]. O valor RMS fornece a indicação de que houve um aumento de energia de vibração devido ao desenvolvimento do defeito [23]. Para um sinal em tempo discreto  $x(n)$ , com  $N$  amostras, o valor RMS pode ser obtido como

$$X_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n)]^2}. \quad (1)$$

onde  $n = 1, 2, \dots, N$  representa uma janela de tempo ao longo da qual o sinal é observado.

O Fator de Crista ( $F_{cr}$ ) é definido como a razão entre o nível de pico da vibração pelo nível RMS,

$$F_{cr} = \frac{X_{pico}}{X_{rms}}. \quad (2)$$

Quando uma máquina rotativa está sem defeitos, com rolamento em boas condições, o sinal de vibração é composto por uma parte predominantemente aleatória somada a uma componente harmônica proveniente de um desbalanceamento residual. Nesta condição, o fator de crista varia entre 2 e 6. Quando o rolamento da máquina sofre um dano, o nível de pico da aceleração aumenta mais rapidamente do que o nível RMS, devido às respostas dos impactos dos elementos rolantes na falha gerada. Assim, o fator de crista atinge valores altos, acima de 6 [26]. No entanto, à medida que o defeito se espalha pela superfície do rolamento, o nível de ruído se eleva, aumentando o valor do nível RMS mais rápido que o valor de pico [26]. Isto produz uma redução no Fator de Crista, de modo que este pode não ser um bom indicador de falhas em um estágio de falha severa [4]. Por essa razão, o Fator K, definido como o produto entre o valor RMS e o valor de pico do sinal,

$$F_k = X_{rms} \cdot X_{pico} \quad (3)$$

pode ser utilizado para contornar a limitação da informação proveniente do Fator de Crista [4].

Propriedades relativas à densidade de probabilidade do processo aleatório associado à vibração também podem ser utilizadas para caracterização de sinais em diferentes condições de defeitos. Em rolamentos sem falha, a densidade de probabilidade do sinal de aceleração normalmente possui características Gaussianas, enquanto que rolamentos com falhas tendem a se desviar desta condição [26]. Neste contexto, vários momentos estatísticos podem ser usados, embora, na prática, momentos de ordem 3 ou 4 sejam suficientes [27].

O terceiro momento estatístico normalizado pelo cubo do desvio padrão é conhecido como assimetria (skewness):

$$S = \frac{1}{N\sigma^3} \sum_{n=1}^N [x(n) - \bar{x}]^3 \quad (4)$$

sendo  $\sigma$  o desvio padrão e  $\bar{x}$  o valor médio do sinal temporal [27], [2]. A equação (4) quantifica a simetria da distribuição dos dados, em que valores negativos indicam assimetria à esquerda da curva de distribuição e valores positivos, assimetria à direita.

O Fator de Curtose é o quarto momento normalizado em relação ao desvio padrão elevado à quarta potência, que indica o achatamento da distribuição e pode ser definido como [27], [2]:

$$K = \frac{1}{N\sigma^4} \sum_{n=1}^N [x(n) - \bar{x}]^4. \quad (5)$$

Para mancais em bom estado, o valor do Fator de Curtose teórico é de 3, aumentando quando há falhas. À medida que a falha se espalha pela superfície da pista ou esfera o Fator de Curtose tende a diminuir, podendo atingir valores iguais ou menores que 3, mascarando uma possível falha no rolamento [28], [29].

Observa-se que há uma diversidade de medidas estatísticas que podem ser usadas para caracterizar formas de onda de vibração e os padrões de anormalidade estão relativamente bem estabelecidos em literatura. Entretanto, o uso simultâneo de todas estas informações pode tornar o diagnóstico confuso em uma abordagem não-automatizada tradicional, sobretudo considerando agravantes como o nível de incerteza do sinal (ruído de medição e/ou o tamanho limitado da série temporal), rotação da máquina, dentre outros. Por este motivo, torna-se importante treinar sistemas computacionais para automatizar a tarefa do reconhecimento do defeito.

É importante ressaltar que a estimativa de todos os atributos propostos é feita a partir da janela temporal em que o sinal de vibração é observado, o que pode introduzir erros se tal janela não for apropriada, e consequentemente levar a diagnósticos incorretos. Por essa razão, uma das propostas deste trabalho é investigar como o diagnóstico é afetado pelo tamanho da janela (registro temporal do sinal ou time record,  $T=N\Delta t$ ) sobre a qual os atributos são calculados. Na verdade, investiga-se a influência (no diagnóstico) do número de amostras  $N$  contidas dentro da janela  $T$ , considerando que o intervalo entre cada amostra  $\Delta t$  é constante nas análises (taxa de amostragem não foi variada).

### B. Algoritmo de Reconhecimento de Padrões

Recentemente houve avanços expressivos na área de estatística e inteligência computacional que permitiram o desenvolvimento de programas capazes de classificar padrões. Um problema de reconhecimento de padrões consiste em ler atributos de um objeto com o intuito de classificá-lo como membro de uma classe pré-definida (treinamento supervisionado) ou usá-lo para definir grupos de objetos com características semelhantes (treinamento não supervisionado). Um problema de diagnóstico de rolamentos pode ser entendido sob este paradigma, em que os atributos do sinal de vibração (objeto) devem ser utilizados para determinar sob qual tipo (classe) de defeito o rolamento que o produziu se encontra.

No trabalho em questão, o classificador testado foi do tipo SVM (Support Vector Machine) [30], cujo treinamento é do tipo supervisionado, em que se supõe conhecida a condição de defeito sob a qual cada forma de onda coletada se encontra. Classificadores SVM têm sido aplicados com sucesso a uma variedade de problemas, tais como reconhecimento de caracteres e de objetos. Alguns dos motivos para esse sucesso estão relacionados ao fato dessa técnica exibir boa generalização e ter uma teoria bem fundamentada [31].

Classificadores SVM são normalmente treinados para problemas binários, onde se deseja distinguir entre apenas duas classes (“com defeito” e “sem defeito”, por exemplo), mas também podem ser ajustados para problemas do tipo multiclasse (usando a estratégia “todos contra um”), a qual foi usada no presente trabalho.

A entrada do classificador SVM é o vetor de atributos do objeto que se quer classificar. A saída do algoritmo é um score, cujo sinal (positivo ou negativo) descreve se o vetor testado pertence ou não a cada uma das classes de interesse, que é apresentada ao usuário diretamente como o rótulo da classe detectada.

### C. Aquisição e Processamento dos Dados de Vibração

Os dados utilizados para a investigação proposta são provenientes de um banco aberto, oferecido pela Case Western Reserve University (CWRU) [32], [33]. O banco de dados consiste de sinais de vibração de rolamentos de esferas rígidas produzidos a partir de uma bancada em laboratório, obtidos sob diferentes condições de funcionamento. Os sinais são estacionários, porém foram coletados sob diferentes rotações. Para esta análise a pista externa é considerada fixa.

A bancada de testes é ilustrada na Fig. 1 e é composta por um motor de 2 HP Reliance Electric, acelerômetro e transdutor de torque. O acelerômetro foi instalado em base magnética na carcaça do motor na posição vertical (12 horas). Os sinais foram coletados a uma taxa de 12.000 amostras/s [33].

Os rolamentos são do tipo 6205-2RS JEM SKF, de esferas rígidas, cuja especificação é: diâmetro interno 25,001mm; diâmetro externo 51,998mm; espessura 15,001mm; diâmetro das esferas 7,94mm; diâmetro primitivo 39,04mm; número de esferas 9, ângulo de contato 0°. Os rolamentos suportam o eixo do motor. Os defeitos foram gerados utilizando usinagem por eletroerosão e foram introduzidos separadamente na pista interna, pista externa e esfera, em tamanhos que variam de




Fig. 1: Bancada - Banco de dados Case Western Reserve University [33].

0,007 a 0,028 polegadas de diâmetro [8]. Neste trabalho, foram utilizados apenas os dados referentes aos diâmetros de 0,007" e 0,021", com profundidade da falha de 0,011", coletados sob rotação de 1730 rpm e carga do motor de 3HP. Este registro foi escolhido devido ao elevado volume de amostras para cada condição do rolamento, sendo um dos mais completos do dataset.

Os sinais provenientes do banco são relativamente longos, mas há apenas uma forma de onda para cada condição do rolamento. Para treinar um classificador que reconheça as falhas, entretanto, é necessário dispor de diversos exemplos de cada condição. Sendo assim, foi proposto o particionamento de cada sinal disponível em janelas retangulares não sobrepostas, de modo que, cada vetor de atributos calculado sobre uma determinada janela pode ser considerado um exemplo da condição do rolamento associada à forma de onda de onde a janela foi extraída.

Todavia, uma preocupação imediata nesta estratégia é o comprimento das janelas de cálculo. Isto é importante porque, como os atributos propostos são derivados a partir de amostras contaminadas com ruído, uma janela muito curta pode não ser suficiente para produzir atributos consistentes, o que inviabiliza o treinamento do classificador. Por outro lado, aumentar o tamanho das janelas implica em uma diminuição do número de exemplos, o que tende a produzir um treinamento “mais difícil” para os classificadores. Este impasse motiva uma investigação sobre a influência do tamanho da janela sobre a qualidade dos atributos. Foram testadas janelas de diferentes tamanhos, desde 100 até 2000 amostras. Um subconjunto de janelas é utilizado para treinar os classificadores (50% do total de janelas) enquanto que outro é utilizado para validá-los. As classes do problema foram estabelecidas conforme a Tabela I.

## III. RESULTADOS E DISCUSSÃO

Para cada janela estabelecida, foram calculados os atributos estatísticos conforme as equações (1) a (5). As Figs. 2-6 ilustram boxplots de cada um, utilizando janelas de 1000 amostras, separados de acordo com as classes estabelecidas. Nestes gráficos é possível perceber a dificuldade em diferenciar alguns dos defeitos utilizando estes atributos.

Através das medianas observadas na Fig. 2 é possível perceber que o valor RMS varia consideravelmente quando o rolamento sai da condição normal, mas não permite distinguir entre os defeitos.

TABELA I: Correspondência entre classes e condição do rolamento

Classe	Condição
1	Sem defeito (SD)
2	Com defeito 0,007" na pista interna (PI7)
3	Com defeito 0,007" na pista externa (PE7)
4	Com defeito 0,007" na esfera (ESF7)
2	Com defeito 0,021" na pista interna (PI21)
3	Com defeito 0,021" na pista externa (PE21)
4	Com defeito 0,021" na esfera (ESF21)




Fig. 2: Boxplot RMS

Observando-se o fator de crista Fig. 3, verifica-se que a orientação geral de que o defeito pode ser constatado a partir do limiar de 6 (estabelecido em literatura) nem sempre é válida, considerando que a condição não é satisfeita para alguns casos de defeito na pista interna, externa e esfera de diâmetro 0,007" e na pista interna e esfera de diâmetro 0,021".




Fig. 3: Boxplot Fator Crista

Analisando apenas o Fator K, Fig. 4, observa-se que os casos de rolamento sem defeito e com defeito de diâmetros 0,007" e 0,021" na esfera também são ambíguos.




Fig. 4: Boxplot Fator K

Para o valor de curtose (Fig. 5) a orientação é que o defeito se verifica para valores maiores que 3, mas ao analisar a dispersão dos valores, não ficam evidentes os defeitos de 0,007" e 0,021" na esfera. Ambiguidades semelhantes são observadas também na análise de assimetria, Fig. 6.




Fig. 5: Boxplot Curtose




Fig. 6: Boxplot Skewness

Esta análise demonstra que, isoladamente, os atributos propostos não permitem distinguir de forma inequívoca entre os defeitos propostos. Contudo, considerando a variação expressiva deles diante de cada uma das situações, é natural cogitar que uma análise combinada, porém não-trivial, possa resolver as ambiguidades existentes entre as classes. Isto, portanto, justifica uma abordagem automática baseada em aprendizagem de máquina.

Para realizar a classificação automática, foram treinados classificadores SVM com kernels lineares, cujo vetor de entrada é formado pelos atributos: RMS, Fator de crista, Fator K, Curtose e Skewness. Em cada rodada de treinamento os atributos foram calculados em um comprimento diferente de janela. A influência do tamanho da janela foi avaliada analisando-se o desempenho dos classificadores em termos de acurácia. O resultado é apresentado na Fig. 7, onde o desempenho global em distinguir entre as sete classes (acurácia) foi plotado em função do tamanho da janela.

Ainda na Fig. 7, nota-se que quanto maior a janela, melhor é o desempenho do classificador, o que é sensato, já que uma janela mais longa tende a conter mais informações relevantes para caracterizar a distribuição do sinal. A curva da Fig. 7 converge para janelas de 800 amostras, para as quais o desempenho não melhora muito significativamente. Esta seria, portanto, a janela que melhor concilia comprimento e acurácia. É interessante observar ainda que uma janela de 800 amostras corresponde a um tempo de observação de 67 milissegundos, que é quase o dobro do ciclo de rotação (34,68 ms), mostrando que são necessários pelo menos dois giros completos da máquina para que o algoritmo classifique corretamente.




Fig. 7: Acurácia em função do tamanho da janela, para classificador treinado para distinguir 7 classes

A matriz confusão para o classificador treinado com os cinco atributos calculados com a janela de 800 amostras está ilustrada na Tabela II.

TABELA II: Matriz Confusão - Janelas de 800 amostras

Classe esperada	Classe verdadeira						
	1	2	3	4	5	6	7
1	30	0	0	0	0	0	0
2	0	30	1	0	0	0	0
3	0	0	29	0	0	2	0
4	0	0	0	30	0	0	0
5	0	0	0	0	30	0	0
6	0	0	0	0	0	28	0
7	0	0	0	0	0	0	30

Observa-se que na Tabela II houve apenas 3 erros entre os dados de teste. Uma amostra pertencente à classe 3 foi categorizada como classe 2 (defeitos em diferentes pistas, mas mesmo tamanho) e duas da classe 6 foram reconhecidas como classe 3 (ambos pista externa). É interessante observar que no primeiro caso, houve uma dificuldade em distinguir a localização do defeito, que estava na pista externa, mas foi detectado como sendo na pista interna, embora a amplitude (0,007") tenha sido correta. É possível que isto tenha ocorrido devido ao fato de defeitos pequenos produzirem formas de onda cujas características possam ser facilmente confundidas. No entanto, a baixa ocorrência deste erro sugere que isto tende a ser raro. No segundo caso, o defeito foi localizado corretamente, mas o tamanho foi subestimado.

A matriz confusão para o classificador treinado com os atributos calculados com a janela de 1000 amostras está ilustrada na Tabela III. São observados apenas 2 erros entre os dados de teste; duas amostras pertencente à classe 6 foram categorizadas como classe 3 (ambos defeitos de pista externa, porém diâmetro diferente). O defeito foi localizado corretamente na pista externa, porém houve dificuldade em distinguir o tamanho do defeito entre 0,007" e 0,021", o que pode ter ocorrido devido a distribuição dos exemplos.

Observa-se que, no geral, o treinamento não apresentou dificuldades de gerar classificadores com acurácia quase absoluta,

TABELA III: Matriz Confusão - Janelas de 1000 amostras

Classe esperada	Classe verdadeira						
	1	2	3	4	5	6	7
1	30	0	0	0	0	0	0
2	0	30	0	0	0	0	0
3	0	0	30	0	0	2	0
4	0	0	0	30	0	0	0
5	0	0	0	0	30	0	0
6	0	0	0	0	0	28	0
7	0	0	0	0	0	0	30

sugerindo que os dados provenientes da pesquisa [8] são bem representativos das condições do rolamento. Isto fica claro ao analisar os gráficos de espalhamento, Figs. 8 e 9, onde cada exemplo do conjunto de validação é ilustrado em termos de apenas duas coordenadas. Neste caso, foram utilizados os atributos RMS e fator de crista como coordenadas principais. A separação entre as classes é bastante nítida, sendo possível isolá-las linearmente, conforme ilustrado (observar que as linhas desenhadas não representam o classificador, e servem apenas de ilustração). Isto ressalta a qualidade dos dados do experimento, assim como o sucesso do classificador SVM com núcleos lineares.




Fig. 8: Gráfico espalhamento-Janela de 800 amostras.




Fig. 9: Gráfico espalhamento-Janela de 1000 amostras.

Observa-se que o nível RMS é suficiente para diferenciar entre quase todas as classes, exceto a classe 6 (defeito pista externa 0,021"), para a qual o fator crista torna-se absolutamente necessário para distingui-la das classes 2 (defeito pista interna 0,007") e 3 (defeito pista externa 0,007"). Notar, contudo que tal separação entre as classes só é obtido para um janelamento de 1000 amostras.

A análise da Fig. 9 levantou a conjectura de que um classificador treinado apenas com dois atributos seria capaz de ter o mesmo desempenho, o que levou a uma investigação secundária, onde foram treinados classificadores cujo atributo

primário fosse o valor RMS, combinado a apenas um dos outros. O resultado é apresentado na Tabela IV.

TABELA IV: Acurácia para classificadores baseados em dois atributos

Classificador	Acurácia (%)
RMS e Crista	98.6
RMS e Fator K	97.1
RMS e Curtose	99.0
RMS e Skewness	96.7

Conforme os resultados de acurácia obtidos para as sete condições do rolamento, a hipótese parece válida ao observar que a combinação dos atributos RMS e Curtose apresentaram elevada acurácia. Uma investigação mais profunda é recomendada, entretanto, para verificar se estes resultados podem estar sofrendo de tendenciosidade nos dados ou dependência de parâmetros, como a velocidade de rotação.

#### IV. CONCLUSÃO

Devido à importância do diagnóstico de falhas em rolamento, no processo de manutenção de um sistema mecânico no setor industrial, este trabalho colabora através da apresentação de duas investigações sobre o uso de atributos estatísticos. Verificou-se que:

- Atributos estatísticos são formas eficazes para distinguir entre diferentes condições do rolamento. As elevadas acurácias obtidas sugerem forte indício de que os sinais de vibração possuem padrões estatísticos plenamente caracterizados por momentos de até ordem 4.
- Classificadores SVM podem ser treinados com alta eficiência (99%) ao usar os atributos estatísticos estudados como preditores, desde que sejam calculados em uma janela de tempo suficiente longa.
- Para a velocidade de rotação investigada, observou-se que a janela de 800 amostras (com intervalo de amostragem 67 ms, pela taxa de amostragem usada) é a janela limite para classificação SVM linear satisfatória. Janelas maiores produzem melhorias pouco significativas na acurácia (<1%).
- A análise de combinações de atributos mostrou que o valor RMS e Curtose do sinal oferecem um conjunto minimalista de atributos capazes de distinguir entre sete classes diferentes de estados do rolamento, nas condições oferecidas pelo experimento.

É importante observar que os atributos considerados funcionam bem para o caso estacionário estudado, porém é possível que a abordagem falhe em situações de velocidade variável. Além disso, se a taxa de amostragem não for ajustada corretamente em rotações superiores, haverá menos informação por ciclo de rotação, o que pode levar à estimativas incorretas dos atributos e, portanto, perda de acurácia.

Por fim, deve-se observar que o desempenho de qualquer classificador dependerá fortemente dos atributos escolhidos. Embora o classificador SVM no contexto deste trabalho seja bastante robusto, os resultados demonstram a viabilidade de se realizar diagnóstico de rolamentos através de classificadores

deste tipo. Apesar de resultados positivos, é importante expandir esta investigação para analisar a influência de circunstâncias, tais como a velocidade de rotação, a presença de outros tipos de defeitos e combinações de atributos estatísticos sobre a acurácia, para uma visão mais definitiva sobre o emprego deste tipo de técnica em sistemas reais de diagnóstico.

#### AGRADECIMENTOS

Os autores agradecem à Pró-Reitoria de Pesquisa e Pós-Graduação UFPA (PROPESP) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro fornecido para que a pesquisa fosse realizada.

#### REFERENCES

- [1] M. Cerrada, R.-V. Sánchez, C. Li, F. Pacheco, D. Cabrera, J. V. de Oliveira, and R. E. Vásquez, "A review on data-driven fault severity assessment in rolling bearings," *Mechanical Systems and Signal Processing*, vol. 99, pp. 169–196, 2018.
- [2] N. Medeiros M Nascimento, S. P. P. Silva, P. P. Reboucas Filho, and C. Marques Sa Medeiros, "Higher-order statistics applied to machine learning as an approach to identify broken rotor bars in induction motors," *IEEE Latin America Transactions*, vol. 16, no. 8, pp. 2267–2274, Aug 2018.
- [3] T. Barszcz and N. Sawalhi, "Fault detection enhancement in rolling element bearings using the minimum entropy deconvolution," *Archives of Acoustics*, vol. 37, no. 2, pp. 131–141, 2012.
- [4] R. A. Bezerra, "Detecção de falhas em rolamentos por análise de vibração," Ph.D. dissertation, Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, SP, 2004.
- [5] J. Sun, C. Yan, and J. Wen, "Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning," *IEEE Transactions on Instrumentation and Measurement*, vol. 67, no. 1, pp. 185–195, Jan 2018.
- [6] T. S. Barbosa, D. D. Ferreira, D. A. Pereira, R. R. Magalhães, and B. H. G. Barbosa, "Fault detection and classification in cantilever beams through vibration signal analysis and higher-order statistics," *Journal of Control, Automation and Electrical Systems*, vol. 27, no. 5, pp. 535–541, Oct. 2016. [Online]. Available: <https://doi.org/10.1007/s40313-016-0255-1>
- [7] A. Diogo Spacek, O. Hideo Ando Junior, J. Mota Neto, V. Coelho, M. Oliveira, L. Shaeffer, and V. Gruber, "Management of mechanical vibration and temperature in small wind turbines using zigbee wireless network," *IEEE Latin America Transactions*, vol. 11, no. 1, pp. 512–517, Feb 2013.
- [8] J. A. Antonino-Daviu, A. Quijano-Lopez, M. Rubbiolo, and V. Climente-Alarcon, "Advanced analysis of motor currents for the diagnosis of the rotor condition in electric motors operating in mining facilities," *IEEE Transactions on Industry Applications*, vol. 54, no. 4, pp. 3934–3942, July 2018.
- [9] S. F. Stefanon, J. R. Oliveira, A. S. Coelho, and L. H. Meyer, "Diagnostic of insulators of conventional grid through labview analysis of fft signal generated from ultrasound detector," *IEEE Latin America Transactions*, vol. 15, no. 5, pp. 884–889, May 2017.
- [10] N. Katsifarakis, M. Riga, D. Voukantsis, and K. Karatzas, "Computational intelligence methods for rolling bearing fault detection," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 38, 12 2015.
- [11] R. Liu, B. Yang, E. Zio, and X. Chen, "Artificial intelligence for fault diagnosis of rotating machinery: A review," *Mechanical Systems and Signal Processing*, vol. 108, pp. 33–47, 2018.
- [12] A. K. Jardine, D. Lin, and D. Banjevic, "A review on machinery diagnostics and prognostics implementing condition-based maintenance," *Mechanical Systems and Signal Processing*, vol. 20, no. 7, pp. 1483–1510, 2006.
- [13] J. Cheng, D. Yu, and Y. Yang, "A fault diagnosis approach for gears based on imf ar model and svm," *EURASIP Journal on Advances in Signal Processing*, vol. 2008, no. 1, p. 647135, May 2008. [Online]. Available: <https://doi.org/10.1155/2008/647135>


- [14] A. Rai and S. Upadhyay, "An integrated approach to bearing prognostics based on eemd-multi feature extraction, gaussian mixture models and jensen-rényi divergence," *Applied Soft Computing*, vol. 71, pp. 36 – 50, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1568494618303727>
- [15] J.-H. Zhong, P. K. Wong, and Z.-X. Yang, "Fault diagnosis of rotating machinery based on multiple probabilistic classifiers," *Mechanical Systems and Signal Processing*, vol. 108, pp. 99 – 114, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0888327018300657>
- [16] A. Stetco, F. Dinmohammadi, X. Zhao, V. Robu, D. Flynn, M. Barnes, J. Keane, and G. Nenadic, "Machine learning methods for wind turbine condition monitoring: A review," *Renewable Energy*, vol. 133, pp. 620 – 635, 2019. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S096014811831231X>
- [17] M. R. G. Meireles, P. E. M. Almeida, and M. G. Simoes, "A comprehensive review for industrial applicability of artificial neural networks," *IEEE Transactions on Industrial Electronics*, vol. 50, no. 3, pp. 585–601, June 2003.
- [18] Z. Zhou, C. Wen, and C. Yang, "Fault isolation based on k-nearest neighbor rule for industrial processes," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 4, pp. 2578–2586, April 2016.
- [19] V. Muralidharan and V. Sugumaran, "A comparative study of naïve bayes classifier and bayes net classifier for fault diagnosis of monoblock centrifugal pump using wavelet analysis," *Applied Soft Computing*, vol. 12, no. 8, pp. 2023 – 2029, 2012.
- [20] B.-S. YANG and A. WIDODO, "Support vector machine for machine fault diagnosis and prognosis," *Journal of System Design and Dynamics*, vol. 2, no. 1, pp. 12–23, 2008.
- [21] Z. Yin and J. Hou, "Recent advances on svm based fault diagnosis and process monitoring in complicated industrial processes," *Neurocomputing*, vol. 174, pp. 643 – 650, 2016.
- [22] P. Kankar, S. C. Sharma, and S. Harsha, "Fault diagnosis of ball bearings using machine learning methods," *Expert Systems with Applications*, vol. 38, no. 3, pp. 1876 – 1886, 2011.
- [23] E. A. Sikora, "Detection of bearing damage by statistic vibration analysis," *IOP Conference Series: Materials Science and Engineering*, vol. 124, p. 012167, apr 2016.
- [24] M. D. Prieto, G. Cirrincione, A. G. Espinosa, J. A. Ortega, and H. Henao, "Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks," *IEEE Transactions on Industrial Electronics*, vol. 60, no. 8, pp. 3398–3407, Aug 2013.
- [25] P. Gangsar and R. Tiwari, "A support vector machine based fault diagnostics of induction motors for practical situation of multi-sensor limited data case," *Measurement*, vol. 135, pp. 694 – 711, 2019.
- [26] A. L. A. Mesquita, D. Santiago, R. Bezerra, U. Miranda, M. D. Jr., and R. Pederiva, "Detecção de falhas em rolamentos usando transformadas tempo-frequência - comparação com análise de envelope," *Mecânica Computacional*, vol. 21, pp. 1938–1954, Oct. 2002.
- [27] G. Casella and R. L. Berger, *Statistical Inference*, 2nd ed. Duxbury, Thomson Learning, 2001.
- [28] S. Kokil, S. Y. Gajjal, M. M. Shah, and S. D. Kokil, "Detection of fault in rolling element bearing using condition monitoring by experimental approach," *International Journal of Engineering Research & Technology*, vol. 3, no. 8, Aug. 2014.
- [29] N. Tandon and A. Choudhury, "A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings," *Tribology International*, vol. 32, no. 8, pp. 469 – 480, 1999.
- [30] V. N. Vapnik, *The nature of statistical learning theory*, 2nd ed. Springer-Verlag, 1995.
- [31] I. Steinwart and A. Christmann, *Support Vector Machine*, 1st ed. Springer-Verlag, 2008.
- [32] W. A. Smith and 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.
- [33] —, "Case western reserve university bearing data center," accessed on Sept, 27, 2018. [Online]. Available: <https://csegroups.case.edu/bearingdatacenter/home>



**Jusley da Silva Souza** Possui graduação em Engenharia Mecânica (2012) pela Universidade Federal do Pará. Master of Business Administration-MBA em Gerenciamento de Projetos pela Fundação Getúlio Vargas-Faculdade Porto Velho (2016). Formada em Língua Estrangeira (Inglês) pelo Centro Cultural Anglo-Americano (2010). Experiência profissional como Engenheira Mecânica na Usina Hidrelétrica Jirau-Porto Velho/RO, Usina composta por 2 Casas de Forças, com 50 máquinas tipo Bulbo de 75 MW, totalizando potência de 3.750 MW (2014-2015).



**Marcus Vinícios Luz dos Santos** Possui graduação em Engenharia Mecânica pela Universidade Federal do Pará (2019). Atualmente trabalha como Analista de Manutenção em uma empresa de mineração de grande porte. Tem experiência com análise de falhas, projetos de estruturas e sistemas mecânicos e programação.



**Rafael Suzuki Bayma** Possui graduação em Engenharia Elétrica pela Universidade Federal do Pará (2005) e mestrado em Engenharia Elétrica pela Universidade Federal do Pará (2006). Possui PhD pelo Department of Automatic Control and Systems Engineering, The University of Sheffield, United Kingdom (2014). Tem experiência na área de Engenharia Elétrica, com ênfase em Processamento de Sinais, Identificação de Sistemas e Sistemas de Controle, atuando principalmente nos seguintes temas: identificação de modelos NARMAX polinomiais,

séries de Volterra, análise de sistemas não-lineares no domínio da frequência e aplicações à diagnóstico de faltas.



**Alexandre Luiz Amarante Mesquita** Possui graduação em Engenharia Mecânica pela Universidade Federal do Pará (1992), Mestrado em Engenharia Mecânica pela Universidade de Brasília (1996) e Doutorado em Engenharia Mecânica pela Universidade Estadual de Campinas (2004). Atualmente é Professor Associado IV do Curso de Engenharia Mecânica na Universidade Federal do Pará. Possui experiência na área de Dinâmica Aplicada, atuando principalmente nos seguintes temas: Vibrações, Análise Modal, Dinâmica de Rotores, Processamento de Sinais e Acústica.

cessamento de Sinais e Acústica.