

Rápida Detecção de Condição de Bombas Centrífguas por Análise Estrutural de Sinais de Sensores MEMS^{*}

Matheus A. dos Santos^{*} Rodrigo D. B. de Araújo^{**}
Geraldo L. B. Ramalho^{***}

^{*} *Graduação em Engenharia Mecatrônica, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: matheus.santos@lapisco.ifce.edu.br).*

^{**} *Graduação em Engenharia Mecatrônica, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: rodrigo.douglas.bernardo07@aluno.ifce.edu.br).*

^{***} *Departamento de Indústria, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: gramalho@ifce.edu.br)*

Abstract: Predictive maintenance techniques allows equipments to be monitored without the need to interrupt its operation, reducing the frequency of corrective maintenance. This work proposes a non-invasive vibration detection system to analyze the state of a three-phase electric machine used in the centrifugal pump using a micro electro-mechanical system (MEMS) sensor composed of accelerometer and gyroscope of multi-axes. The structural analysis provided a means of extracting time domain signal characteristics. Classification was performed in order to analyze signal attributes from different combinations on three axes. The results show that using the signals from accelerators and gyroscopes improves the performance of classifiers, as is the case with Linear SVM, which reached 100% for all monitoring conditions. In addition, the extraction of signal attributes using the SCM structural analysis method is fast enabling it to be used in embedded systems.

Resumo: Técnicas de manutenção preditiva permitem que os equipamentos sejam monitorados sem a necessidade de interromper sua operação, reduzindo a frequência de manutenção corretiva. Este trabalho propõe um sistema não-invasivo de detecção de vibração para analisar o estado de uma máquina elétrica trifásica usada na bomba centrífuga usando um sensor de sistema micro eletromecânico (MEMS) composto por acelerômetro e giroscópio de múltiplos eixos. A análise estrutural forneceu um meio de extrair as características do sinal no domínio do tempo. A classificação foi realizada para analisar os atributos do sinal de diferentes combinações em três eixos. Os resultados mostram que o uso dos sinais de aceleradores e giroscópios melhora o desempenho dos classificadores, como é o caso do Linear SVM, que atingiu 100% para todas as condições de monitoramento. Além disso, a extração dos atributos do sinal usando o método de análise estrutural do SCM é rápida, permitindo que seja usado em sistemas embarcados.

Keywords: Condition monitoring; Predictive maintenance; Structural analysis; Feature extraction; Machine learning; MEMS; Centrifugal pump.

Palavras-chaves: Monitoramento de condição; Manutenção preditiva; Análise estrutural; Extração de atributos; Aprendizado de máquina; MEMS; Bomba centrífuga.

1. INTRODUÇÃO

A vibração produzida por uma máquina pode ser um bom indicativo do seu estado atual, já que tende a variar bastante em função do estado de conservação, formando padrões que podem ser extraídos e classificados, como mencionado por Ramalho et al. (2014). No ambiente industrial, por exemplo, métodos de manutenção preditiva têm se fortalecido como alternativas às formas corretiva e preventiva, pois se baseiam, ao contrário das demais,

em uma análise contínua ou periódica do comportamento e da integridade de uma máquina a fim de diminuir as intervenções, impactando diretamente a produção.

Nesse contexto, surgem vários métodos para a análise contínua da integridade de uma máquina, como o protótipo desenvolvido por González et al. (2014), baseado no uso da Transformada Rápida de Fourier (FFT). Sua justificativa principal seria a alta capacidade de replicação se comparado ao uso de sensores piezo-elétricos convencionais, já que utilizara, em sua construção, um sensor MEMS em conjunto a um microcontrolador Arduino Due, com alta disponibilidade no mercado.

^{*} Os autores agradecem o apoio financeiro por meio dos projetos PIBIC-FUNCAP-IFCE, Edital 65/2019 e PIBITI-CNPq-IFCE, Edital 66/2019.

Pedotti et al. (2019), por sua vez, fizeram um sistema de análise de vibração utilizando acelerômetro triaxial do sensor MEMS, processando os sinais capturados com a FFT junto a técnicas de *machine learning* para encontrar falhas de forma preventiva. Os melhores resultados foram atribuídos à utilização do espectro completo do sinal como entrada para os classificadores, sem o uso de um descritor eficiente. Além disso, não foram testados outros tipos de sinais de vibração além da aceleração nos eixos x e y . Da mesma forma, ALTobi et al. (2019) também utilizaram apenas sinais de aceleração, extraídos por Transformada Wavelet, para comparar o desempenho de dois classificadores (MLP e SVM) acerca do diagnóstico de falha em bombas centrífugas. Os melhores resultados (taxa de aprendizado 99,5%) foram obtidos ao utilizar o classificador MLP otimizado com Algoritmo Genético, o que demanda um alto custo computacional e um maior tempo para treinamento.

Neste trabalho, portanto, é desenvolvido um sistema para detectar o estado de funcionamento de uma bomba centrífuga de forma não invasiva visando a baixa complexidade e altas disponibilidade de material e capacidade de replicação. Isso se dá através de um trabalho que une a eletrônica de sensores MEMS e o uso de técnicas de classificação para identificar diferentes situações, como mudanças na frequência de operação do motor da bomba, analisando o desempenho do sistema em classificar os sinais capturados de um ou mais eixos espaciais.

O principal objetivo deste trabalho consiste em encontrar a melhor combinação entre os sinais de aceleração e giroscópio, ao fazer uma série de experimentos de classificação, com sete classificadores diferentes, e comparar os seus desempenhos à luz de uma série de métricas de avaliação. Além disso, espera-se propor um modelo de aquisição com algoritmo simples, de processamento e resposta rápidos, a fim de garantir a sua aplicabilidade em sistemas embarcados.

O restante do trabalho se divide como se segue. A seção 2 trata da metodologia utilizada, compreendendo o modelo físico experimental, a comunicação com o servidor, a aquisição e o processamento dos dados e a forma de avaliação dos modelos utilizados. A seção 3 apresenta e discute os resultados obtidos, a partir de visualizações gráficas. Por fim, a última seção antes da bibliografia, trata das conclusões e de sugestões de trabalhos futuros.

2. METODOLOGIA

Este trabalho utiliza como metodologia a detecção do estado de funcionamento de uma bomba centrífuga industrial baseado na captura e posterior classificação dos padrões de vibração gerados por seu motor quando em funcionamento. É proposto ainda que essa análise seja feita de forma não invasiva, não necessitando parar a máquina para realizá-la.

2.1 Modelo experimental

Estrutura física do Sistema. O sistema de captura é formado por um sensor de vibração e um microcontrolador funcionando como cliente de um servidor operando na rede local, que recebe seus dados e os salva para

posteriores extração de características e classificação dos dados. Durante o desenvolvimento, foi utilizado o módulo nodeMCU, trazendo consigo o microcontrolador ESP8266, cujos destaques são a alta capacidade de processamento e a conectividade *Wi-Fi* integradas.

O módulo comunica-se com um sensor de aceleração e giro MEMS de três eixos através do protocolo *Inter-Integrated Circuit* (I2C) para a captura dos dados de vibração. Após a captura de um pacote de leituras, o módulo então transfere todos os dados para um servidor instalado em um computador local através do protocolo *WebSocket*, permitindo alta velocidade de transferência com baixa perda de dados. A Figura 1 ilustra de forma simplificada o funcionamento do sistema.

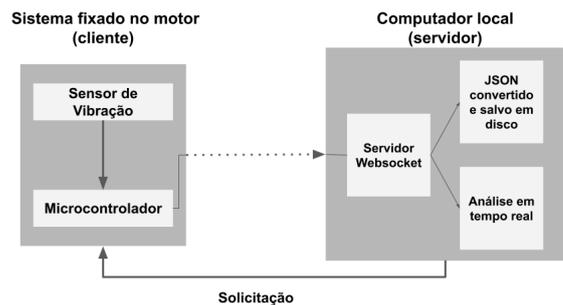


Figura 1. Os dados são capturados pelo sensor, que os envia para o microcontrolador, responsável por enviar o pacote para o servidor instalado localmente. Os dados então podem ser vistos em tempo real ou salvos em disco para análise futura. Isso tudo se dá após uma solicitação do servidor para que o cliente inicie o processo de captura de dados.

Como o sistema proposto deveria funcionar de forma não invasiva, foi fabricado um recinto protetor em impressora 3D para comportar o sensor e o módulo nodeMCU, como ilustrado na Figura 2.

O recinto conta com um encaixe na parte inferior para comportar bases de diferentes formatos, permitindo-o funcionar em diversas superfícies simplesmente trocando sua base. A fixação do sistema no corpo do motor se dá através de ímãs de neodímio localizados dentro do recinto protetor, permitindo maior fixação e consequente fidelidade na captura dos dados.

Os eixos cujos dados foram capturados correspondem a 3 acelerômetros e 3 giroscópios, compostos cada um por X, Y e Z. Nos experimentos, o eixo X foi alinhado na direção radial horizontal com relação ao eixo do motor. O eixo Y, por sua vez, foi alinhado na direção axial, e o eixo Z na direção radial vertical.

2.2 Aquisição dos dados

O sensor MEMS empregado neste trabalho funciona com até 1000 leituras por segundo para o sensor de aceleração e 8000 leituras por segundo para o sensor giroscópio. Contudo, devido a limitações do sistema desenvolvido para a captura dos sinais, a amostragem realiza cerca de 367 leituras por segundo, se considerados os 6 sensores de posição e um sensor de temperatura.

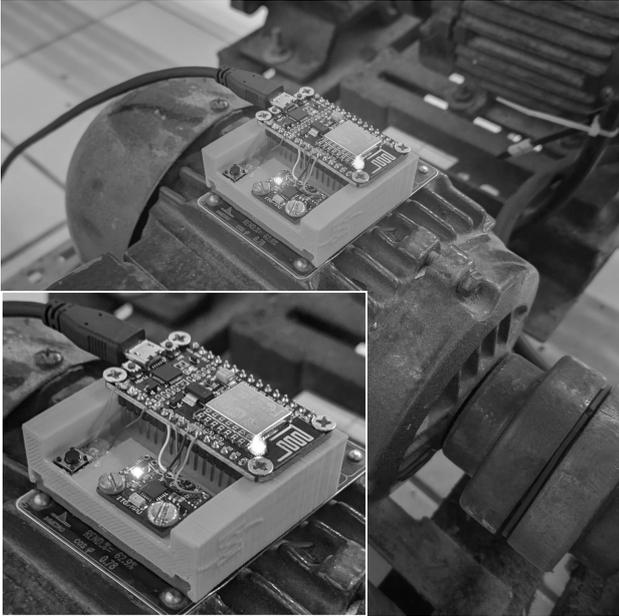


Figura 2. Sistema montado na parte superior do motor. É possível observar o microcontrolador e o sensor na imagem, sendo alimentados por uma fonte de 5 Volts. Os formatos de onda obtidos em cada eixo podem variar de acordo com a orientação e posição do sensor. Por isso, neste trabalho todas as capturas foram realizadas com o sensor na mesma posição.

Para a transmissão dos dados dos sensores, utiliza-se o protocolo de comunicação *Websocket*, que consiste em um transporte bidirecional de informações entre clientes e servidor baseado em eventos (Farias and Vasconcelos, 2019). *WebSocket* se diferencia de protocolos como *Hypertext Transfer Protocol* (HTTP) principalmente devido ao fato de não necessitar que uma conexão seja aberta e fechada sempre que houver um transporte de dados. A conexão, nesse caso, é mantida até que todos os dados sejam enviados, não havendo tempo de espera entre um envio e outro. Assim, *WebSocket* se destaca por sua maior velocidade, permitindo que seja utilizado em muitas aplicações sem a necessidade de repetidas requisições de conexão.

Neste trabalho, foi desenvolvido um servidor *WebSocket* para trabalhar em um computador local, recebendo os dados enviados pelo sensor, também através desse protocolo, cuja velocidade será discutida no próximo tópico.

Após a captura dos dados, o microcontrolador envia os dados ao servidor através de *WebSocket*. O protocolo criado para a comunicação sem fios do sistema com o servidor local transfere os dados de 2500 leituras dos sensores em 3,2 segundos, taxa de 781 leituras por segundo. Convém lembrar que cada amostra contém dados dos 6 sensores de vibração, entre acelerômetro e giroscópio, e um sensor de temperatura cujos dados foram descartados nos experimentos.

Os eixos espaciais capturados pelo acelerômetro são, a partir daqui, chamados como AcX, AcY e AcZ, enquanto os eixos do giroscópio são mencionados como GyX, GyY e GyZ.

Foram realizadas capturas em um subprocesso da planta de processos contínuos do Laboratório de Automação e Redes Industriais (LARI). Uma bomba centrífuga foi submetida a condições diferentes de operação, variando sua velocidade de rotação e a quantidade de água do tanque.

2.3 Pré-processamento e extração de características

Após a aquisição dos dados, tem-se que uma única captura é formada por seis sinais diferentes (referentes aos três eixos de aceleração e aos três eixos de giroscópio), com 2500 leituras cada. A fim de avaliar o processo de monitoramento em tempo real, cada sinal foi dividido em 25 sinais menores, com 100 leituras cada. No entanto, várias capturas foram feitas, em diferentes condições de funcionamento, totalizando um *dataset* formado por 850 amostras, sendo cada uma delas composta pelos sinais de eixo de aceleração e giro concatenados na horizontal (AcX, AcY, AcZ, GyX, GyY, GyZ, respectivamente).

Por fim, o *dataset* foi ajustado, a fim de garantir o balanceamento entre as classes, tomando como base a classe com menos amostras (classe 3, com 25 amostras). Para esse balanceamento, selecionou-se de forma aleatória 25 amostras de cada uma das demais classes, descartando os dados restantes. A Tabela 1 detalha o *dataset* final, bem como explicita as diferenças entre cada classe envolvida na etapa de classificação.

Tabela 1. Descrição do *dataset* final, formado a partir de várias capturas de sinais de vibração para uma mesma bomba d'água.

Classe	Quantidade de amostras	Frequência de atuação	Água no tanque
0	25	25 Hz	Sim
1	25	25 Hz	Não
2	25	30 Hz	Sim
3	25	30 Hz	Não
4	25	35 Hz	Sim
Total	125		

Com os dados já organizados, utilizou-se a Matriz de Coocorrência Estrutural (SCM, do inglês *Structural Co-occurrence Matrix*), um algoritmo para análise estrutural de sinais, como extrator de atributos. Nesse trabalho, o objetivo de se usar extratores de características, também chamados de descritores, é selecionar parâmetros que melhor descrevem o sinal, a fim de que o classificador, que será empregado posteriormente, possa encontrar padrões e classificá-los corretamente. Dessa forma, cada sinal, composto por 100 leituras, passará a ser representado por uma quantidade bem menor de parâmetros, chamados de *atributos*.

A Matriz de Coocorrência Estrutural – SCM, proposta por Ramalho et al. (2016), é um algoritmo de análise estrutural de imagens e sinais no domínio do tempo que, ao ser usado como um extrator de características, gera um conjunto de oito atributos (*COR, IDM, ENT, CSD, CSR, MDR, DKL, CAD*). Os dois primeiros são atributos estatísticos do sinal, enquanto *ENT* mede a entropia e os últimos cinco são medidas de divergência. Na forma de extrator a SCM realiza

o comparativo entre dois sinais f e g , sendo g a versão degradada de f .

Foram utilizados oito níveis de quantização, o que resulta em uma matriz quadrada de 64 elementos. Para obter g , foi utilizado um filtro de suavização gaussiano de dimensões 3×3 para eliminar possíveis ruídos e obter a degradação de f destacando os padrões mais marcantes do sinal de entrada.

2.4 Classificação supervisionada dos padrões de vibração

A classificação dos dados se deu por meio do uso de uma série de classificadores, analisando seu desempenho em três experimentos principais. No primeiro, foi testado cada eixo de cada um dos sensores individualmente para verificar qual seria mais importante para a determinação do estado do motor. Em seguida, foram testados os dois sensores separadamente, com cada um contendo seus 3 eixos espaciais. Por último, foi pretendido classificar os dados a partir de todo o *dataset*, utilizando todos os sensores de aceleração e giro simultaneamente. A Tabela 2 descreve cada um dos três experimentos.

Para todas as classificações feitas, foram usadas todas as cinco classes do *dataset*, simultaneamente e com pesos iguais, tratando-se de classificações do tipo multiclasse.

Tabela 2. Descrição dos experimentos que foram realizados na etapa de classificação.

Experimento	Descrição	Sinais de vibração utilizados
1	Classificação por sinal de eixo	AcX AcY AcZ GyX GyY GyZ
2	Classificação por tipo de sensor	AcX+AcY+AcZ GyX+GyY+GyZ
3	Classificação com dataset completo	AcX+AcY+AcZ+GyX+GyY+GyZ

Nesse trabalho, utilizou-se de sete classificadores: Naive Bayes, MLP, *k-Nearest Neighbors*, Random Forest e três versões de SVM (Linear, Polinomial e RBF). Os parâmetros de entrada variáveis para cada um deles – exceto o classificador Naive Bayes, que não leva parâmetros – foram escolhidos por meio de um algoritmo de busca aleatória (do inglês, *Random Search*), variando de acordo com o *dataset* utilizado. Na Tabela 3 estão representados os intervalos de busca para cada um dos parâmetros variáveis.

O Classificador de Naive Bayes é um método de *machine learning* baseado na *Regra de Bayes*, que assume que cada valor presente no vetor de característica é independente em relação aos outros (Muralidharan and Sugumaran, 2012), e a partir disso faz uma análise estatística do vetor como um todo. Por outro lado, o classificador Perceptron multicamadas (do inglês, *Multi-layer Perceptron* - MLP) é um método de classificação baseado no cérebro humano, utilizando de neurônios artificiais, os chamados *perceptrons* (Rosenblatt, 1958). A maior diferença para o perceptron simples é que o perceptron multicamadas é composto por várias camadas ocultas entre a entrada e a saída (ALTobi et al., 2019). Como parâmetros fixos para o MLP, foi utilizado um teto de 1000 iterações e taxa de aprendizagem inicial de 5×10^{-4}

Outro algoritmo de aprendizado supervisionado que foi utilizado foi o *k-Vizinhos mais próximos* (do inglês, *k-Nearest Neighbors* - kNN). Sua ideia geral consiste em

Tabela 3. Intervalos de busca dos parâmetros de cada classificador, a fim de garantir a melhor arquitetura pelo algoritmo de busca aleatória, ou *Random Search*.

Classificador	Parâmetros buscados	Intervalos de busca
Naive Bayes	-	-
MLP	Camadas ocultas	[2, 1000]
kNN	Número de vizinhos mais próximos	1, 3, 5, 7, 9, 11
Random Forest	Profundidade máxima Bootstrap Critério	6, Ilimitada Verdadeiro, Falso Gini, Entropia
SVM Linear	Parâmetro de regularização (C)	$2^x x \in [-5, 15]$
SVM Polynomial	Grau Parâmetro de regularização (C)	3, 5, 7, 9 $2^x x \in [-5, 15]$
SVM RBF	Gamma Parâmetro de regularização (C)	$2^x x \in [-15, 3]$ $2^x x \in [-5, 15]$

encontrar k amostras já rotuladas mais próximas de uma ainda não classificada e, com base no rótulo dessas, atribuir um rótulo ao exemplo desconhecido (Aha et al., 1991). O algoritmo Random Forest (Ho, 1998), baseado nas árvores de decisão, também foi usado como classificador, utilizando-se de 3000 estimadores e inicialização aleatória. Por fim, as máquinas de vetores de suporte (do inglês, *Support Vector Machine* - SVM) são métodos de classificação baseados em hiperplanos de separação ótima das amostras em um espaço multidimensional (Yuan and Chu, 2006). Foram usados três tipos de *kernel* para o classificador SVM (linear, polinomial e RBF), e cada variação foi tratada como um classificador independente. A tolerância para os três foi fixa e igual a 10^{-3} .

Os demais parâmetros não mencionados aqui foram mantidos com os valores padrão da biblioteca *scikit-learn*, versão 0.22.2, que foi a biblioteca usada para implementação de todos os classificadores destacados acima.

O treinamento se deu por meio do método *K-fold* de validação cruzada, com 10 *folders*. Esse método garante que, ao fim das 10 iterações, todas as amostras terão passado pelo classificador, visto que o *dataset* é dividido em 10, e a cada rodada, um desses grupos é utilizado para teste, enquanto os outros nove são usados para treinamento. O desempenho de cada modelo, após predição do conjunto de teste, foi avaliado por um conjunto de métricas, apresentadas na seção seguinte.

2.5 Métricas para avaliação de desempenho

As métricas utilizadas para avaliar o desempenho dos classificadores em cada experimento foram: acurácia (Acc), precisão, sensibilidade, especificidade e *F1-Score*.

Todas as métricas são calculadas com base nos verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos, obtidos da *matriz de confusão*. Na análise, são consideradas as médias aritméticas dos resultados de classe.

Além das métricas citadas acima, os tempos médios de treinamento e de predição dos classificadores foram adicionados como parâmetros de referência para avaliar o tempo de extração das características do sinal.

3. RESULTADOS

A seguir são apresentadas algumas visualizações das amostras utilizadas em cada etapa do processamento, assim como os resultados finais da avaliação de cada modelo para cada um dos experimentos realizados. Todos os algoritmos aqui utilizados foram implementados em Python (versão 3.5.2) e por meio das bibliotecas NumPy, Pandas, Matplotlib (para visualização gráfica) e scikit-learn 0.22.2, para implementação dos classificadores.

3.1 Análise visual dos padrões de vibração

Durante os testes, foi observado que a amplitude e o padrão da onda produzida pela vibração do motor da bomba centrífuga variam de acordo com a velocidade de operação. A Figura 3 exemplifica esses padrões.

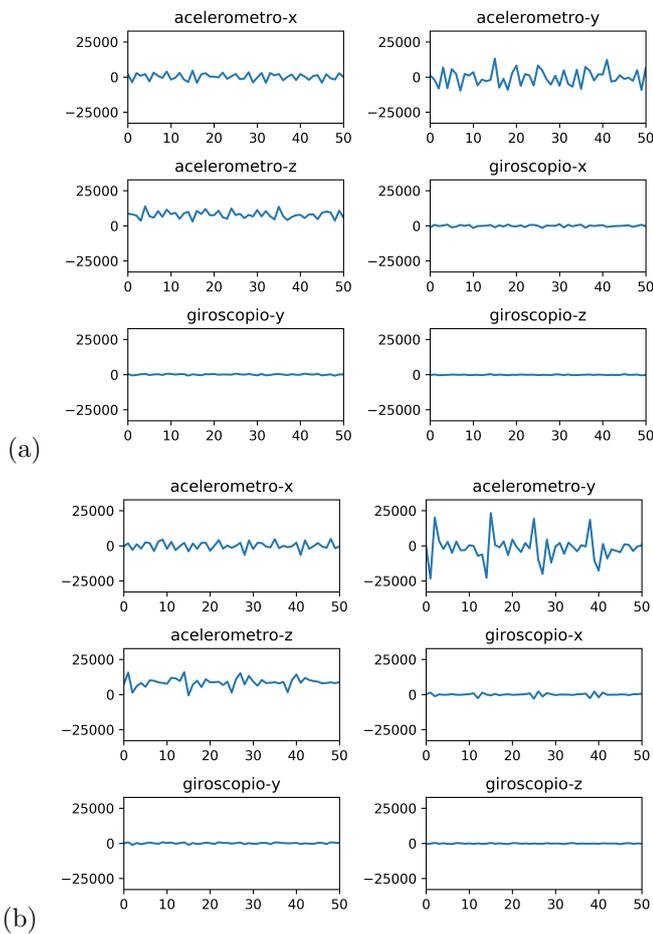


Figura 3. Comparação gráfica dos sinais de vibração obtidos pelo sensor com a bomba funcionando em diferentes situações. Em (a), o sinal da bomba funcionando a 25 Hz, onde a onda é menos definida; em (b), a bomba funcionando a 30 Hz, com a periodicidade da onda tornando-se mais perceptível, além de notável diferença de amplitude e formato de onda. Vale ressaltar que mais testes foram realizados, obtendo-se resultados semelhantes.

Além da frequência, foi observado que a quantidade de água no tanque também seria responsável por deformações na onda gerada. Contudo, seria necessário um trabalho

exclusivo e observações a fim de confirmar ou não essa hipótese. Caso positivo, um sistema de classificação semelhante a este poderia ser desenvolvido para estimar a quantidade de água num tanque.

3.2 Visualização gráfica dos atributos extraídos e análise do tempo de extração

As amostras do sinal de cada um dos seis eixos foram analisadas através da visualização gráfica de dispersão, a fim de notar se há superposição entre classes ou se elas tendem a ser distintas, o que facilita a classificação. À primeira vista, é notório que há alguma separação entre sinais de diferentes classes, enquanto que amostras de uma mesma classe formam grupos, ou *clusters*, com alguma superposição entre si.

A disposição das amostras em relação aos atributos está exemplificada na Figura 4. Devido à SCM, utilizada como extrator, gerar mais de três atributos por sinal, não é possível ilustrar essa visualização em um gráfico multidimensional, portanto, optou-se por fazer uma análise dos atributos de dois em dois.

Ao analisar o mosaico da Figura 4(a) é possível notar que principalmente a classe 1, representada em azul, e a classe 4, representada em vermelho, se diferenciam bem mais que as outras em certos quadros, enquanto em outros há uma maior superposição. Para esse exemplo, do sinal de aceleração no eixo x (AcX), é esperado que essas duas classes sejam mais facilmente previstas pelos classificadores.

Por fim, ao analisar os tempos de extração, que é um importante fator para o monitoramento de condição, o método de análise estrutural SCM levou em média 5,63 milissegundos, com desvio-padrão de 1,6 milissegundos, para descrever uma única amostra, com os seis tipos de sinal. Ou seja, para descrever um único sinal de eixo, seja de aceleração ou giro, a SCM leva cerca de 1/6 desse tempo.

3.3 Análise de desempenho de cada modelo treinado

Nessa seção, são apresentados os resultados obtidos com as métricas de avaliação para cada um dos experimentos, apresentados na Tabela 2, comparando os tipos de sinal utilizados e os classificadores supracitados, a fim de encontrar as combinações com os melhores resultados.

A Tabela 4 compara os resultados de acurácia e os tempos de treino, predição e extração para cada combinação experimento-classificador. Os valores atingidos pelas outras métricas serão mencionados e discutidos por experimento, a seguir.

Experimento 1: Classificação utilizando sinais individuais de eixo. Para esse experimento foram feitas seis classificações, utilizando em cada uma delas um dos seis sinais de eixo (três de aceleração e três de giro). Os sinais de giro mostraram resultados inferiores aos sinais de aceleração, o que mostra que, pelo menos de forma individual e separados, a aceleração nos três eixos é uma melhor medida para análise de vibração, a fim de predizer condições de atuação da bomba.

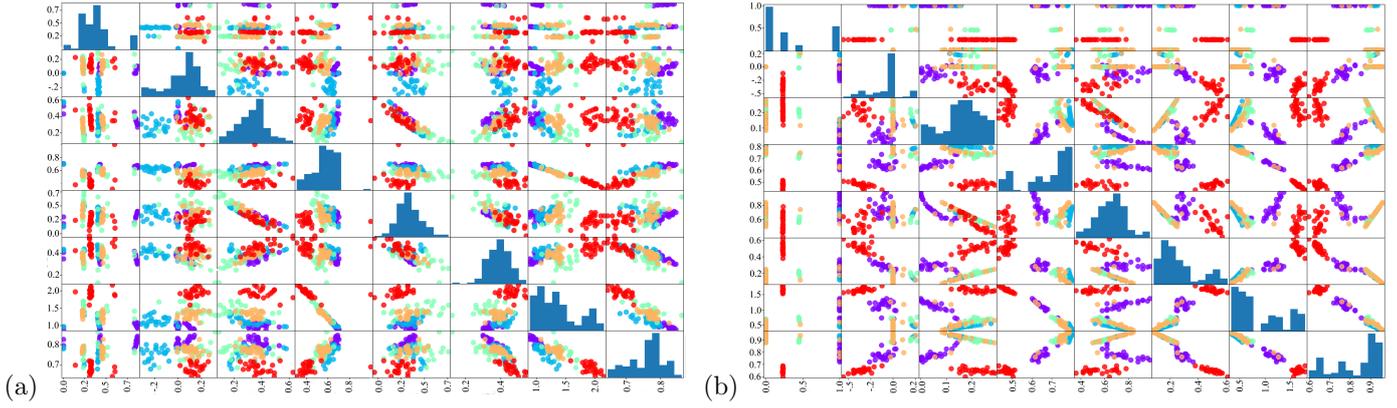


Figura 4. Visualização gráfica da dispersão das amostras após a etapa de extração. Cada linha e coluna da matriz gráfica corresponde a um dos oito atributos extraídos pelo extrator SCM. Em (a) trata-se do sinal de aceleração no eixo x (AcX), enquanto em (b) trata-se do sinal de giro no eixo x (GyX). As classes de 0 a 4 estão representadas pelas cores roxo, azul, ciano, laranja e vermelho, respectivamente.

Tabela 4. Acurácia (Acc) e os respectivos tempos de treino, predição e extração para combinações de sinais de vibração utilizados e classificadores. A variabilidade presente nas métricas são decorrentes do uso do K -fold.

Classificador	Acc (%)	Tempo de treino (ms)	Tempo de predição (ms)	Tempo de extração (ms)
Sinais utilizados: AcX+AcY+AcZ				
Naive Bayes	93,53 ± 6,19	2,7 ± 1,2	1,6 ± 0,5	
MLP	95,13 ± 5,46	3444,2 ± 786,2	2,8 ± 1,6	
Nearest Neighbors	93,59 ± 7,73	1,2 ± 0,4	1,7 ± 0,6	
Random Forest	95,9 ± 6,68	6001,2 ± 946,8	333,0 ± 75,5	2,88 ± 1,4
SVM Linear	97,56 ± 3,72	6,0 ± 0,8	1,8 ± 0,4	
SVM Polinomial	85,58 ± 7,23	7,8 ± 1,3	1,3 ± 0,5	
SVM RBF	78,33 ± 10,97	16,8 ± 1,7	1,9 ± 0,3	
Sinais utilizados: GyX+GyY+GyZ				
Naive Bayes	88,85 ± 7,18	1,4 ± 0,5	0,8 ± 0,6	
MLP	91,99 ± 6,3	1904,0 ± 295,2	2,1 ± 0,3	
Nearest Neighbors	92,05 ± 3,45	1,5 ± 0,5	1,5 ± 0,5	
Random Forest	91,99 ± 5,08	3208,9 ± 30,4	221,8 ± 5,1	2,88 ± 1,4
SVM Linear	91,15 ± 7,77	4,0 ± 0,6	0,7 ± 0,5	
SVM Polinomial	90,45 ± 6,79	4,0 ± 0,4	0,4 ± 0,4	
SVM RBF	84,68 ± 5,97	16,0 ± 9,0	0,8 ± 0,4	
Sinais utilizados: AcX+AcY+AcZ+GyX+GyY+GyZ				
Naive Bayes	96,03 ± 5,26	1,5 ± 0,7	1,1 ± 0,5	
MLP	98,33 ± 3,33	2340,4 ± 580,9	2,5 ± 0,7	
Nearest Neighbors	96,79 ± 3,93	1,3 ± 0,5	1,7 ± 0,5	
Random Forest	99,23 ± 2,31	3793,4 ± 401,1	316,6 ± 56,8	5,63 ± 1,6
SVM Linear	100,0 ± 0,0	5,1 ± 1,0	1,2 ± 0,4	
SVM Polinomial	91,35 ± 6,37	8,8 ± 1,4	1,4 ± 0,5	
SVM RBF	98,33 ± 3,33	11,6 ± 0,7	1,1 ± 0,5	

O melhor resultado na classificação dos sinais de eixo de giro se deu com os sinais GyX e com o classificador MLP. Essa combinação atingiu 91,99% ± 6,3% de acurácia, 93,33% ± 5,53% de precisão, 91,66% ± 6,54% de sensibilidade, 97,99% ± 1,62% de especificidade e 91,36% ± 6,53% para o F1-Score. Enquanto o pior resultado para giro se deu com GyZ, em que nenhum classificador conseguiu acima de 40% para qualquer métrica, exceto por especificidade, que mostra resultados na faixa dos 80%. O que mostra que esse tipo de sinal pouco contribui para uma boa separação entre classes.

Para os sinais de eixo de aceleração, os melhores resultados foram vistos para sinais de AcX e AcY, enquanto AcZ mostrou resultados um pouco mais baixos. Destaca-se, por exemplo, a combinação AcX-SVM Linear, que atingiu 92,88% ± 5,42% de acurácia, 94,70% ± 4,05% de precisão, 93,33% ± 4,94% de sensibilidade, 98,25% ± 1,35% de especificidade e 92,48% ± 5,59% para o F1-Score. Os

demais classificadores, para sinais AcX ou AcY, atingiram resultados menores, porém bem próximos.

Experimento 2: Classificação utilizando sinais de um mesmo tipo de sensor. Esse experimento consiste em duas classificações: uma com os sinais dos três eixos de aceleração e outra com os sinais dos três eixos do giroscópio, a fim de comparar as duas classificações e chegar ao tipo de sensor que melhor se adequa para uso como sinal de vibração. Os resultados obtidos nesse experimento também foram comparados aos resultados obtidos no experimento anterior, como mostra a Figura 5.

Analisando a Figura 5, é notório que o *dataset* composto pelos sinais dos três eixos de aceleração (representados em vermelho) apresentam resultados superiores aos outros dois para cinco dos sete classificadores. Apenas para o classificador SVM Polinomial tem-se os melhores resultados atribuídos aos sinais GyX+GyY+GyZ (representado em verde), enquanto o classificador SVM RBF melhor classificou o *dataset* apenas com os sinais de AcX.

Os melhores resultados para essas duas classificações foram obtidos novamente pelo classificador SVM Linear, com os sinais AcX+AcY+AcZ. Para essa combinação, obteve-se 97,56% ± 3,72% de acurácia, 98,17% ± 2,83% de precisão, 97,67% ± 3,67% de sensibilidade, 99,40% ± 0,93% de especificidade e F1-Score de 97,45% ± 3,92%. A Tabela 4 também mostra a diferença dos resultados para as duas classificações desse experimento, em termos de acurácia e tempo de classificação.

Experimento 3: Classificação com o dataset completo. Por fim, no último experimento, fez-se uma classificação única, com o *dataset* completo, ou seja, com todos os tipos de sinal em análise (AcX+AcY+AcZ+GyX+GyY+GyZ). Isso aumenta a dimensão do vetor de atributos utilizado pelo classificador, possibilitando uma melhora no desempenho do modelo, visto que em um espaço multidimensional pode haver uma melhor separação entre as classes. No entanto, também é possível que piore o desempenho do classificador ao incluir sinais do tipo GyZ, por exemplo, que ao ser utilizado individualmente gerou resultados baixíssimos.

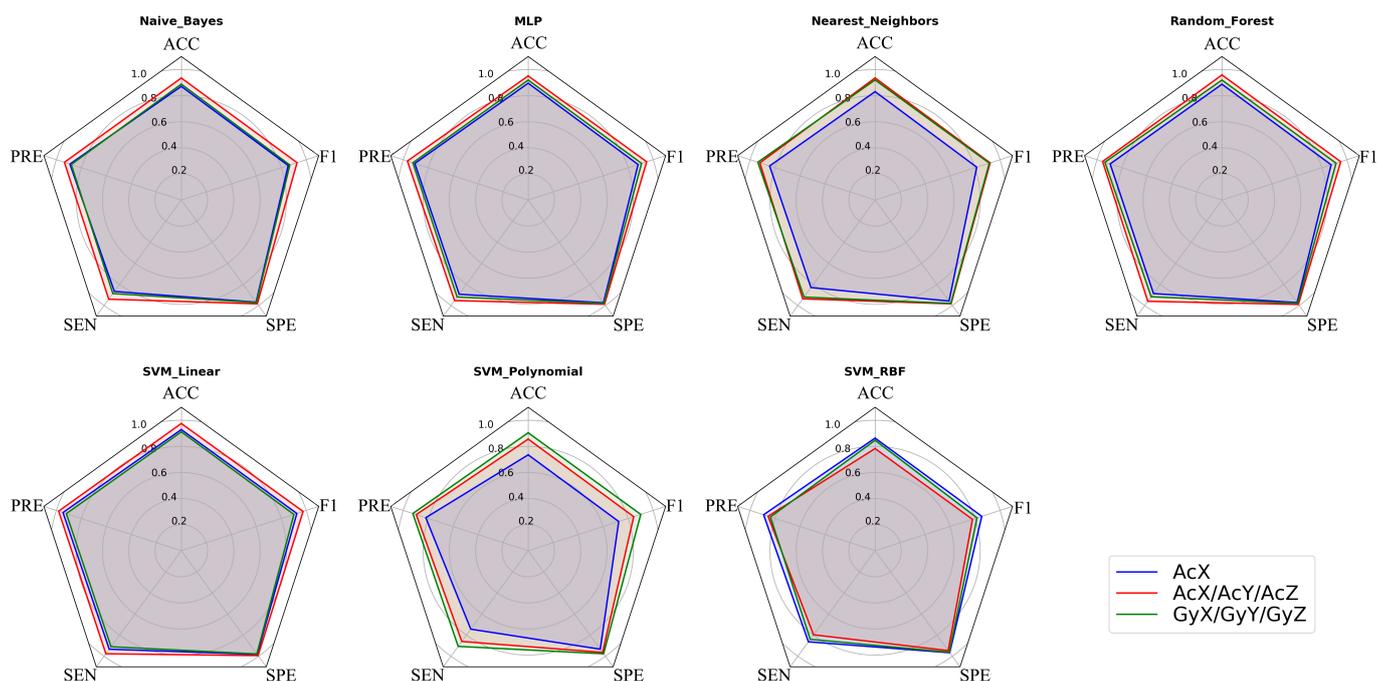


Figura 5. Comparação entre os resultados obtidos por cada classificador, usando dos sinais AcX, AcX+AcY+AcZ e GyX+GyY+GyZ, representados em azul, vermelho e verde, respectivamente. Na Figura, as médias estão representadas por ACC (acurácia), PRE (precisão), SEN (sensitividade), SPE (especificidade) e F1 (F1-Score).

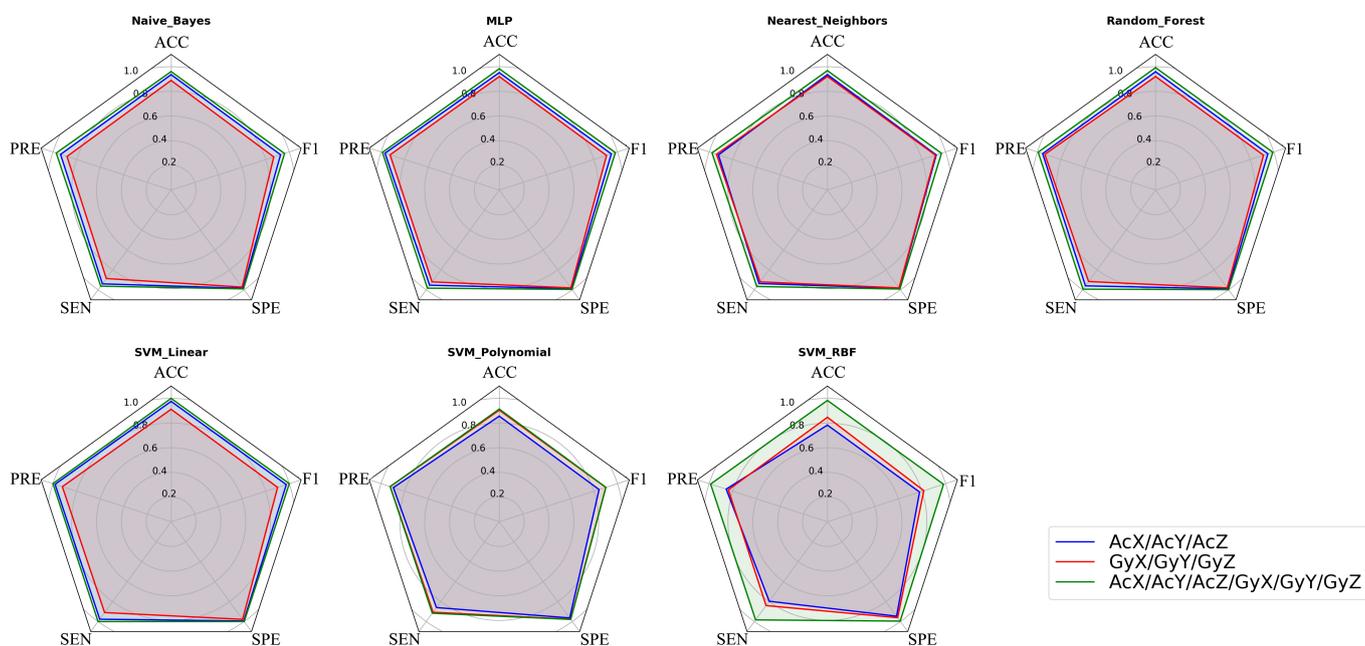


Figura 6. Comparação entre os resultados obtidos por cada classificador, usando dos sinais (nos três eixos) de aceleração, de giro e de aceleração e giro simultaneamente, representados em azul, vermelho e verde, respectivamente. Na Figura, as médias estão representadas por ACC (acurácia), PRE (precisão), SEN (sensitividade), SPE (especificidade) e F1 (F1-Score).

A Figura 6 mostra que, para todos os classificadores, o *dataset* completo, representado em verde, obteve melhor desempenho do que as duas classificações feitas no experimento anterior. Usando o classificador SVM RBF há uma diferença mais perceptível, enquanto para os outros classificadores, tem-se o *dataset* com os sinais dos três eixos de aceleração, em azul, atingindo resultados próximos.

Para esse experimento, o SVM Linear novamente foi o que obteve melhores resultados, atingindo a marca dos 100% para todas as métricas, com desvio-padrão nulo. Ou seja, não houve erros em nenhuma iteração para esse classificador em combinação com esse *dataset*. Todos os demais classificadores, utilizando todos os sinais de aceleração e giroscópio, atingiram resultados acima de 90% para as métricas de avaliação.

4. CONCLUSÕES

Os experimentos realizados para comparar diferentes combinações de modelos *dataset*-classificador, mostraram ser possível detectar de forma rápida e confiável as condições às quais a bomba centrífuga foi submetida a saber, diferentes frequências de rotação e a presença ou não de água no sistema.

Ao analisar os resultados, percebe-se que, utilizar conjuntamente os sinais de aceleração e giroscópio, nos seus três eixos espaciais, favorece o desempenho dos classificadores. Combinado ao classificador SVM Linear, foi possível atingir 100% para todas as métricas de avaliação, com desvio-padrão desprezível. Como desvantagem ao utilizar todos os sinais do sensor MEMS simultaneamente, obtivemos um aumento no tempo de extração. No entanto, o método de análise estrutural SCM, utilizado como extrator de características, provou-se bastante rápido, o que torna essa diferença pouco significativa.

Para trabalhos futuros, pretende-se integrar as técnicas estudadas em um dispositivo de IoT (do inglês, *Internet of Things*), associando o monitoramento simultâneo de várias bombas, de forma a ser possível uma análise remota em tempo real sem a necessidade de pausas na operação. Também pretende-se ampliar as condições de operação da bomba, com a diminuição dos degraus de frequência e avaliação para diferentes níveis de água no tanque, além de eventuais imperfeições mecânicas do equipamento.

REFERÊNCIAS

- Aha, D.W., Kibler, D., and Albert, M.K. (1991). Instance-based learning algorithms. *Machine learning*, 6(1), 37–66.
- ALTobi, M.A.S., Bevan, G., Wallace, P., Harrison, D., and Ramachandran, K. (2019). Fault diagnosis of a centrifugal pump using mlp-gabp and svm with cwt. *Engineering Science and Technology, an International Journal*, 22(3), 854–861.
- Farias, E.M.B. and Vasconcelos, F.H. (2019). Protocolo websocket em hardware restrito para redes de sensores sem fio.
- González, R.C.D. et al. (2014). *Desenvolvimento de um protótipo analisador de vibração de baixo custo para uso em manutenção preditiva*. Mestrado em engenharia mecânica, Universidade Federal de Santa Catarina, Florianópolis.
- Ho, T.K. (1998). The random subspace method for constructing decision forests. *IEEE transactions on pattern analysis and machine intelligence*, 20(8), 832–844.
- Muralidharan, V. and Sugumaran, V. (2012). A comparative study of naïve bayes classifier and bayes net classifier for fault diagnosis of monoblock centrifugal pump using wavelet analysis. *Applied Soft Computing*, 12(8), 2023–2029.
- Pedotti, L.A.d.S. et al. (2019). *Dispositivo IoT de baixo custo para Diagnóstico de Falhas em Máquinas Rotativas*. Doutorado em engenharia elétrica, Universidade Estadual de Campinas, Campinas.
- Ramalho, G.L.B., Ferreira, D.S., Rebouças Filho, P.P., and de Medeiros, F.N.S. (2016). Rotation-invariant feature extraction using a structural co-occurrence matrix. *Measurement*, 94, 406–415.
- Ramalho, G.L.B., Pereira, A.H., Rebouças Filho, P.P., and Medeiros, C.M.d. (2014). Detecção de falhas em motores elétricos através da classificação de padrões de vibração utilizando uma rede neural elm. *Holos*, 4, 185–194.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Yuan, S.F. and Chu, F.L. (2006). Support vector machines-based fault diagnosis for turbo-pump rotor. *Mechanical Systems and Signal Processing*, 20(4), 939–952.