

Descritor de padrões de vibração para monitoramento IoT com processamento local^{*}

Rodrigo D. B. de Araújo^{*} José S. de Souza Neto^{**}
Thais N. de Carvalho^{***} Emerson V. A. Dias^{****}
Geraldo L. B. Ramalho[†] Josias G. Batista[‡]

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

^{**} *Graduação em Engenharia Mecatrônica, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: jose.sampaio.souza00@aluno.ifce.edu.br)*

^{***} *Graduação em Engenharia Mecatrônica, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: thais.neves.carvalho05@aluno.ifce.edu.br)*

^{****} *Graduação em Engenharia Mecatrônica, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: emerson.veras.aragao07@aluno.ifce.edu.br)*

[†] *Departamento de Indústria, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: gramalho@ifce.edu.br)*

[‡] *Departamento de Indústria, Instituto Federal do Ceará, Campus Fortaleza, (e-mail: josiasbatista@ifce.edu.br)*

Abstract:

The occurrence of failures in industrial automatic systems is usually related to a change on the machine's vibration pattern. This work proposes a feature extraction based on the mobile standard deviation and a simple and efficient data classification model to be implemented as local processing of IoT (Internet of Things) systems. The proposed method is evaluated in a simulation of a non-invasive online condition monitoring experiment of a rotating machine, with the objective of detecting the condition of a dry running centrifugal pump. The results obtained reveals that the proposed algorithm has high precision to detect the failure condition on the behavior of the monitored machine. The development of these types of systems makes it possible to integrate them into automated industrial plants.

Resumo:

A ocorrência de falhas em sistemas automáticos industriais está geralmente relacionada a uma mudança no padrão de vibração das máquinas. Este trabalho propõe um método para extração de características baseado no desvio padrão móvel e um modelo de classificação de dados simples e eficiente para ser implementado em processamento local de sistemas IoT (*Internet of Things*). O método proposto é avaliado em um experimento simulado de monitoramento *online* não-invasivo de condição de máquina rotativa, com o objetivo de identificar o funcionamento a vazios de uma bomba centrífuga. Os resultados obtidos mostram que a proposta possui alta precisão para detectar condição de falha no comportamento da máquina monitorada. O desenvolvimento de sistemas desse tipo possibilita sua integração a plantas industriais automatizadas.

Keywords: Vibration descriptor; machine condition monitoring; IoT; non-invasive system.

Palavras-chaves: Leitor de vibrações; monitoramento de condição de máquina; IoT; sistema não-invasivo.

1. INTRODUÇÃO

Plantas industriais automatizadas necessitam de segurança em seu funcionamento, principalmente ao serem levados em conta os altos custos dos equipamentos envolvidos nos processos, como mencionado por Sitompul and Rohmat (2021). Dessa forma, métodos de manuten-

ção preditiva e análise de condição de máquinas foram desenvolvidos para detectar um mau funcionamento no momento em que ele ocorre, como proposto por de Araújo et al. (2022) e no trabalho de González et al. (2014), permitindo que os operadores tomem atitudes antes de ocorrer alguma falha ou acidente, evitando prejuízos para a produção e para a empresa.

Tecnologias como IoT e *Industrial Internet of Things*, provam que são aliadas da indústria, principalmente nas áreas de inovação e segurança. Desta forma, a análise de

^{*} Os autores agradecem o apoio financeiro por meio dos projetos PIBIC-FUNCAP-IFCE, Edital 01/2021 e PIBITI-CNPq-IFCE, Edital 03/2021.

condição de máquina aliada à conectividade em sistema industrial representam uma importante aplicação da internet das coisas (Huda et al., 2018).

Algumas aplicações industriais com IoT foram desenvolvidas para melhorias de equipamentos como *retrofitting* e melhorias no processo de manutenção preditiva. No trabalho desenvolvido por Guerreiro et al. (2018) foi proposto o conceito de *Smart Retrofitting* e sistemas ciberfísicos. Como resultado, a metodologia propõe levar aspectos da Indústria 4.0 relevantes para processos industriais, visto que este pode ser o primeiro passo para uma empresa implementar os conceitos da Indústria 4.0. No trabalho de Lins et al. (2018) foi proposta uma forma de realizar o processo de manutenção preditiva através de uma plataforma que, independente do modelo ou tipo do equipamento industrial, oferece recursos para integrar este equipamento com a Indústria 4.0.

Sistemas de bombeamento de líquido devem prevenir o funcionamento a vazio, devido aos possíveis desgastes nos componentes internos, altas temperaturas e vibrações, que podem causar impactos negativos à produção (Tong et al., 2020). Nesse contexto, sistemas de monitoramento contínuo são de grande importância para garantir a segurança e confiabilidade de um processo automático. Estes sistemas, geralmente, utilizam sensores e sistema de aquisição de dados onerosos, que muitas vezes inviabilizam sua aplicação generalizada dentro de uma indústria.

O objetivo deste trabalho é, portanto, propor um método de extração de características unidimensional inspirado no desvio padrão móvel (do inglês, *Moving Standard Deviation* - MSD) que é utilizado no monitoramento de precisão analítica de resultados clínicos de pacientes, como mostrado no trabalho de Liu et al. (2017). O descritor proposto captura as variações de nível de líquido em um sistema de bombeamento por meio dos sinais de vibração capturados por um sensor do tipo *micro-electromechanical system* (MEMS). Um modelo de classificação de dados de baixa complexidade, treinado com os dados do descritor, é avaliado em um experimento de monitoramento contínuo de condição da máquina, simulando seu uso em sistemas embarcados com processamento local.

O restante do artigo se divide como se segue. A Seção 2 descreve a metodologia para extração de atributos e o tratamento realizado para se fazer a classificação e a avaliação. Na Seção 3 é feita uma discussão sobre os resultados obtidos e uma análise de desempenho do modelo de classificação. Por fim, na Seção 4 apresentamos as conclusões retiradas do estudo dos dados e da resolução do projeto.

2. METODOLOGIA E DESENVOLVIMENTO

Este trabalho utiliza sinais de vibração capturados por um acelerômetro triaxial MEMS de modelo MPU-6050 acoplado a uma bomba centrífuga industrial como pode ser visualizado no modelo da Figura 1. Por sua natureza não invasiva, o sistema pode ser instalado facilmente em máquinas semelhantes. Os sinais são enviados para um computador local onde é realizado o processamento.

Os dados de vibração foram divididos em três situações: Falha, Alerta e Normal. Cada uma é representada por




Figura 1. Representação gráfica da divisão do tanque industrial acoplado à bomba centrífuga conectada ao sistema de aquisição de dados. Observa-se que o tanque divide-se em intervalos de 20 L.

uma classe, caracterizadas da seguinte forma: a Classe 0 representa o estado de falha, quando a bomba está funcionando a vazio; a Classe 1 representa um estado de alerta, quando há menos de 20 L no tanque; por último, a Classe 2 representa um estado de funcionamento normal, quando o nível de líquido está entre 20 e 100 L. As capturas foram realizadas tendo em vista diferentes condições de operação, determinados pelo nível de líquido no tanque ligado à bomba centrífuga. As diferenças no sinal de vibração, de acordo com o nível de líquido presente em um determinado momento da operação, são detectadas por um classificador com o objetivo de gerar alarmes para o sistema de controle do processo.

Foram desenvolvidos métodos para a extração de atributos e classificação dos dados capturados nas diferentes condições, como detalhado a seguir.

2.1 Configuração do sistema

A estrutura estabelecida para a captura dos dados de vibração foi composta por um tanque industrial com capacidade para 100 L de água, com saída ligada a uma bomba centrífuga, que é acionada por meio de um motor de indução controlado por um inversor de frequência. Esse sistema faz parte de uma planta industrial didática automatizada do Laboratório de Automação e Redes Industriais (LARI). O motor da bomba centrífuga funciona a 2.263 RPM, por meio de um sinal de 40 Hz enviado pelo inversor de frequência e as capturas de dados foram realizadas durante seu estado permanente. O sistema é aberto, sem retorno do líquido bombeado.

Neste trabalho, as vibrações causadas por desalinhamento, fixação e estrutura que suporta os equipamentos são consideradas parte do sistema de bombeamento.

2.2 Aquisição dos dados

O monitoramento de vibrações é um método não-invasivo que pode ser facilmente instalado em qualquer máquina rotativa. Neste trabalho, utilizou-se um acelerômetro MEMS

ligado a um microcontrolador de baixo consumo de energia a fim de realizar a captura dos dados. Os dados são armazenados e posteriormente transmitidos para um computador para processamento.

Os dados utilizados neste trabalho foram separados em três classes, de acordo com a quantidade de líquido no tanque ligado à bomba centrífuga, como ilustrado na Figura 1.

Foram coletadas capturas tridimensionais em cada um dos três eixos de aceleração (AcX, AcY e AcZ). Para as classes 0 e 1, onde os quais o nível de água está menor que 20 litros, utilizou-se 3.000 capturas para cada eixo, totalizando 9.000 capturas de sinal para cada uma. Para a classe 2, que abrange os quatro intervalos de 20 litros restantes, foram realizadas 3.000 capturas para cada variação, portanto 12.000 capturas em cada eixo da classe, totalizando 36.000 capturas. O *dataset* final contém, portanto, 54.000 capturas de sinal, se considerados todos os eixos e todas as classes. Os dados foram capturados com um período amostral de 5ms, equivalente a uma frequência amostral de 200Hz, por meio do sensor MEMS digital com 16 bits de resolução, totalizando 65.536 valores de aceleração possíveis, que correspondem à detecção de sinais de até aproximadamente $\pm 19,62m/s^2$. Pode-se observar visualmente a diferença no padrão de vibração em cada eixo do acelerômetro do sensor por meio da Figura 2.

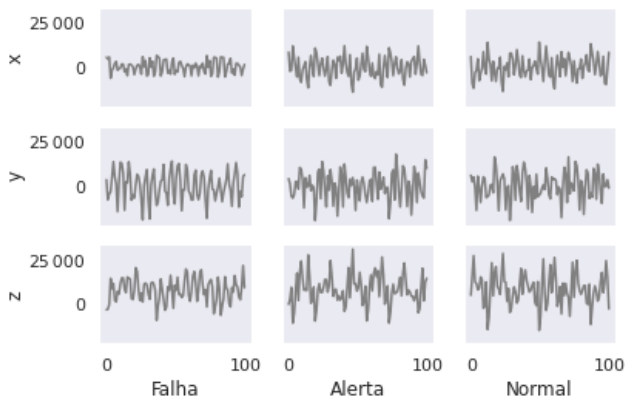


Figura 2. Representação visual dos sinais de vibração pacotes de 100 amostras em cada uma das condições estudadas neste trabalho. O sensor digital envia dados de vibração de 16 bits em cada eixo espacial por meio do protocolo I2C ao microcontrolador. É possível observar que a vibração tende a aumentar quando a condição está mais próxima do normal, quando há mais líquido nos tanques.

Considera-se que, para níveis acima de 20 L, a bomba centrífuga opera em condições normais. Para níveis abaixo de 20 L, a bomba opera normalmente, mas há um aumento do risco de funcionamento a vazio caso ocorram falhas físicas ou erro no sistema de automação, constituindo, portanto, uma condição de alerta. A situação de falha ocorre se o tanque ficar completamente vazio. Essa é uma condição considerada rara, que ocorre somente se o sistema de automação falha. De fato, essa condição deve ser prevista no projeto de um sistema de automação. Entretanto, em caso de erro na lógica de controle ou falhas na instrumentação, as medições de segurança projetadas podem não ser efetivas.

As classes utilizadas na Seção 2.4, referente ao experimento de classificação dos dados, foram separadas na forma descrita na tabela 1. Cada amostra corresponde a 100 capturas de sinal para cada eixo do acelerômetro.

Tabela 1. Descrição do *dataset* utilizado na classificação dos dados.

Classe	Quant. de amostras	Nível de líquido [L]	Condição do sistema
2	120	21 - 100	Normal
1	30	1 a 20	Alerta
0	30	0	Falha
Total	180		

2.3 Extração de características

Devido à baixa taxa de amostragem, determinada por restrições da largura de banda do sensor MEMS e pelo atraso na conversão do sinal do sensor pelo sistema de aquisição. Os dados de amplitude da vibração também são influenciados pela frequência de rotação da bomba, adicionando mais uma variável a ser considerada nas situações apresentadas. Assim, existe uma limitação na captura de detalhes do sinal de vibração que inviabiliza o uso de técnicas baseadas em análise de frequência.

Adotou-se, portanto, a análise destes sinais no domínio do espaço, estimando o nível de variação capturada pela amostragem do sinal de vibração da bomba. Observa-se na Figura 2 que o padrão da variação do sinal possui uma desconformidade significativa para a condição de tanque vazio, quando comparado às demais condições de operação.

Vale ressaltar que o método de extração de características deve ser tão rápido e de simples implementação quanto possível, visando o objetivo de embarcar o método em um sistema *IoT* com processamento local em tempo real. Estabeleceu-se um limite superior de até 0,5s para a extração de características de cada pacote de dados, de forma que, quando submetido a uma situação real, o sistema consiga enviar a classe dos dados a cada 1s. Após a implementação, observou-se que o tempo para a execução de todo o método de extração de características nunca ultrapassou os 0,1s. O desvio padrão é uma medida da tendência do sinal se desviar da média e, portanto, fornece uma boa estimativa da sua variação.

A proposta de extração de características deste trabalho é aplicada a uma amostra contendo 100 capturas de dado, para cada eixo do acelerômetro. A característica variacional do sinal de vibração é capturada com MSD utilizando uma janela deslizante, como demonstrado na Figura 3.

A transformação dos sinais de amplitude em sinais de variação é ilustrada na Figura 4, utilizando

$$MSD_a(t) = \text{std}(x_a(t) * w_h(t)), \quad (1)$$

em que $\text{std}(\cdot)$ é o desvio padrão da convolução $\cdot * \cdot$ entre a janela degrau unitário $w_h(t)$ de tamanho h , centralizada em t , e o sinal de vibração $x_a(t)$ do eixo a .

O valor médio da variação do sinal em cada eixo é, então, computado como

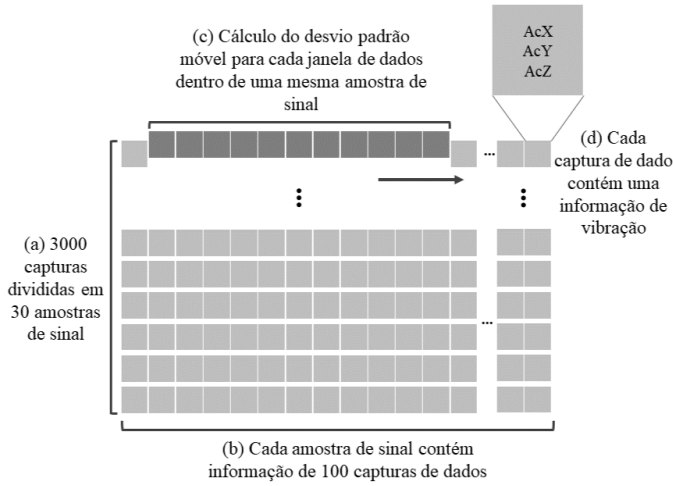


Figura 3. Modelo do extrator de características proposto. O procedimento é repetido para cada uma das classes separadamente.

$$\overline{MSD}_a = \frac{\sum MSD_a}{\#(MSD_a)}, \quad (2)$$

em que $\#(\cdot)$ representa a cardinalidade. Finalmente, o descritor d do sinal amostrado é obtido calculando-se a média quadrática (RMS, do inglês *root mean square*) dos três eixos com a expressão

$$d = \sqrt{\frac{\sum_a \overline{MSD}_a}{3}}. \quad (3)$$

Esse procedimento de extração é simples, de baixa complexidade computacional. Ele pode ser implementado no próprio dispositivo de coleta dos dados e, se utilizando um algoritmo para cálculo incremental do desvio padrão, utiliza recursos mínimos de memória. O tamanho da janela deve ser escolhido de forma que não comprometa uma boa estimativa do desvio padrão, porém deve ter tamanho pequeno o suficiente para otimizar o processamento. Neste trabalho, observou-se empiricamente vários tamanhos para a janela de dados, sendo escolhido $h = 11$ para atender a esses dois requisitos.

O resultado desta operação é um valor escalar para cada sinal amostrado. A distribuição dos dados após o processo de extração de características pode ser visualizado na Figura 5

2.4 Classificador

Visando a implementação em um sistema embarcado de baixo consumo energético, decidiu-se adotar um algoritmo simples baseado em árvore de decisão (Charbuty and Abdulazeez, 2021), cujos limiares de classificação são obtidos com a média e desvio padrão do descritor do sinal.

Os parâmetros da árvore de decisão são determinados utilizando-se 20% dos dados. Os limiares l^c para a classificação são computados com a expressão

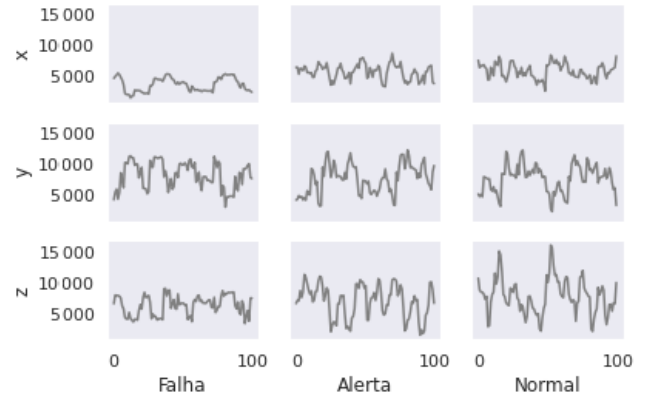


Figura 4. Sinais de variação em cada uma das condições monitoradas a partir dos valores dos eixos x, y e z do acelerômetro. Esses sinais são obtidos após a operação de extração de características sobre o sinal de vibração utilizando uma janela de tamanho 11.




Figura 5. Distribuição dos valores do descritor para cada uma das classes. As linhas pontilhadas representam os limiares que dividem cada classe. Estes limiares foram obtidos por meio da média mais um desvio padrão de cada classe, como descrito na Seção 2.4.

$$l^c = \mu_d^c + \sigma_d^c, \quad (4)$$

em que $c \in \{\text{Falha, Alerta, Normal}\}$, μ_d^c e σ_d^c são a média e o desvio padrão, respectivamente, dos descritores d utilizados para treinamento. A predição da classe p a partir do descritor d do sinal de entrada, é definida como

$$p(d) = \arg \max_c (d - l^c < l^c - d). \quad (5)$$

Neste trabalho, assume-se que a ocorrência de falhas por funcionamento a vazio é um evento raro. Dessa forma, é utilizada uma validação cruzada não estratificada para estimar um desempenho não enviesado da detecção de falhas em uma simulação de monitoramento de condição de uma máquina industrial.

O experimento de classificação é repetido 100 vezes para estimar um desempenho médio, bem como obter uma distribuição das métricas de desempenho. Durante a implementação do modelo, utilizou-se uma divisão de 80% dos dados para treino, e 20% para teste. É possível, então, avaliar a robustez do método proposto em uma simulação da aplicação em monitoramento de condição do sistema.

O objetivo é detectar condições de falhas no sistema de bombeamento, especificamente o funcionamento a vazio, e gerar alarmes para as situações de risco, antes que uma falha ocorra. Durante os experimentos realizados, observou-se que o aumento das repetições não altera a interpretação dos resultados.

2.5 Métricas utilizadas para avaliação

As métricas utilizadas para avaliar o desempenho do modelo de classificação dos dados são precisão, revocação e F1. A *F1 Score* é uma média harmônica entre a precisão e a revocação e permite avaliar o desempenho geral, o que facilita comparar a robustez entre os diferentes casos apresentados. O valor médio ponderado das métricas é utilizado, já que esse tipo de avaliação ponderada é calculado utilizando as médias das *F1 Score* de cada classe quando considerada a quantidade de amostras de sinal de cada uma delas, e, no caso do *dataset* utilizado neste trabalho, tal abordagem justifica-se devido às classes serem desbalanceadas. A F1 ponderada pode ser, portanto, obtida pela seguinte equação, onde F1 representa cada classe e P, a proporção da classe correspondente quando comparado ao conjunto total de dados

$$F1_W = \sum_{i=0}^n F1_i \cdot P_i \quad (6)$$

Contudo, as métricas mais importantes neste trabalho são a precisão e a revocação porque permitem avaliar os detalhes do desempenho da detecção das condições de pré-falha (classe Alerta) e falha (classe Falha), considerando a superposição entre essas classes.

3. RESULTADOS

Os resultados do modelo de classificação baseado no descritor proposto neste trabalho, foram obtidos a partir de um experimento de simulação do monitoramento de condição em um sistema de automação.

A robustez é avaliada com base na média geral e no pior caso das métricas de desempenho de classificação. A classificação como pior e médio casos foi realizada com base nos valores da métrica *F1 Score* de cada teste do modelo.

3.1 Análise de desempenho de classificação

Os resultados mostram que o classificador baseado no descritor proposto possui precisão máxima para a classe Falha. Isto é importante para aplicações de monitoramento contínuo nas quais falsos positivos são indesejáveis, já que podem levar a interrupções indesejadas nos processos do sistema de automação.

Por outro lado, erros de detecção (falsos negativos) de estados de Alerta (classe 1) e Falha (classe 0) foram registrados. Entretanto, falsos negativos são admitidos, já que essas condições provavelmente se repetirão depois que uma falha se torna estável, com grande probabilidade de ser detectada nas próximas amostragens do sinal. A matriz de confusão geral, presente na Tabela 2 mostra que os falsos negativos para as classes Falha e de Alerta são inferiores a 20%.

Tabela 2. Matriz de confusão total dos experimentos

		Predição		
		Falha	Alerta	Normal
Verdade	Falha	503	90	0
	Alerta	0	503	94
	Normal	0	80	2330

É possível observar na Figura 6, que as métricas de avaliação apresentam valores de precisão, revocação e F1-score acima de 90% no melhor caso. Observa-se que, mesmo no pior caso, as métricas se mantêm próximas a 80%.




Figura 6. Resultado da classificação supervisionada avaliado a partir do pior caso, caso correspondente ao desempenho médio e melhor caso. A classificação como pior, médio e melhor casos foi realizada com base nos valores da métrica *F1 Score* de cada teste do modelo.

Quando analisados os resultados do desempenho médio por classe, observa-se que a detecção da condição de falha (classe 0) tem máxima precisão, como pode ser visto na Figura 7. Percebe-se que o descritor possibilita alta sensibilidade e alta especificidade para a detecção da classe Falha. Isso demonstra um ótimo desempenho considerando a capacidade de detecção da condição de falha, com pouco ou nenhum falso alarme. A detecção da condição normal também tem ótima precisão média. Além disso, embora ocorram alguns falsos alarmes para a condição Alerta, isto não acarretaria um parada do sistema de automação.

Mesmo no pior cenário, como ilustrado na Figura 8, os resultados mostram alta precisão para a detecção da classe Falha.

Importante notar que, no pior caso, as métricas precisão e revocação ficaram abaixo de 90% para ambas classes Falha e Alerta. Mesmo com a possibilidade de não detecção da falha, a Tabela 3 mostra que desempenho menores que 90% são muito pouco frequentes, como ilustrado na Figura 9.

Tabela 3. Percentual de métricas de desempenho com valor abaixo de 90%

#(Precisão < 90%)	#(Revocação < 90%)
13%	22%

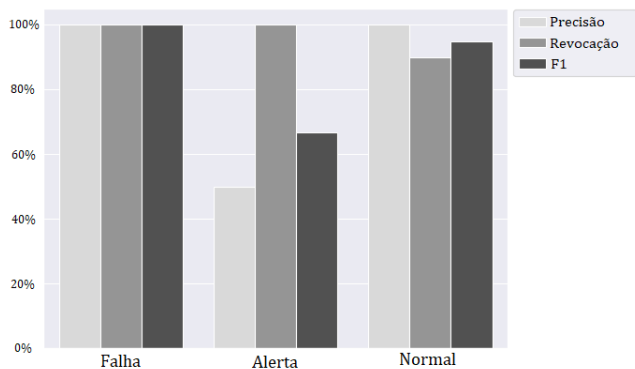


Figura 7. Resultado das classificações correspondente ao desempenho médio, analisado por classe Falha, Alerta e Normal. A alta revocação da classe Alerta e a alta precisão da classe Falha demonstram robustez para a prevenção de falhas.




Figura 8. Resultado do pior caso da classificação analisado classe a classe, entre as classes Falha, Alerta e Normal. Observa-se que até mesmo nesta situação, a detecção de falhas possui alta taxa de precisão, como desejado.

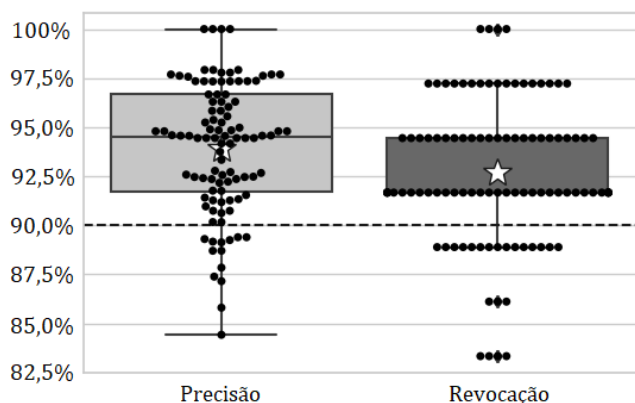


Figura 9. Frequência das métricas de desempenho nos experimentos de classificação. Observa-se que os valores de precisão e de revocação próximos de 95% são mais frequentes.

4. CONCLUSÕES

Os resultados mostram que o método proposto apresenta um comportamento robusto, especialmente em aplicações de monitoramento contínuo de condições da máquina e

como um sistema de suporte na tomada de decisões durante o gerenciamento de alertas em plantas industriais.

O descritor obtido com a extração de características mostra que é possível separar corretamente os dados de cada classe, levando em conta sua aplicação. A classificação do sinal, foi desenvolvida de forma a identificar as diferentes condições de funcionamento visando ser implementada em um sistema embarcado no futuro. Para tal, utiliza-se um método simples de classificação, de forma a consumir pouco poder de processamento quando utilizado em uma aplicação real de monitoramento com sistema IoT, especialmente considerando o processamento local ou na borda.

Por meio dos resultados do experimento, observa-se que é possível identificar a ocorrência de falhas com máxima precisão, ainda que este evento seja bastante raro. Também é possível verificar que ocorrem poucos falsos positivos, que produziram indesejados falsos alarmes.

Para trabalhos futuros, deseja-se validar a metodologia proposta integrando-a a um sistema de planta automatizado. Dessa forma, pretende-se embarcar todo o sistema de extração de características em um microcontrolador, de forma que este realize todo o processamento do sinal localmente.

Adicionalmente, pretende-se examinar métodos adaptativos para ajustar e otimizar os limiares do classificador em tempo real.

REFERÊNCIAS

- Charbuty, B. and Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20–28.
- de Araújo, R.D.B., Rocha, J.M., dos Santos, M.A., and Ramalho, G.L.B. (2022). Fast detection of centrifugal pumps condition by structural analysis of mems sensor signals. *Journal of Control, Automation and Electrical Systems*, 33(1), 293–303.
- 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.
- Guerreiro, B.V., Lins, R.G., Sun, J., and Schmitt, R. (2018). Definition of smart retrofitting: First steps for a company to deploy aspects of industry 4.0. In *Advances in Manufacturing*, 161–170. Springer.
- Huda, S., Yearwood, J., Hassan, M., and Al-Mogren, A. (2018). Securing the operations in scada-iot platform based industrial control system using ensemble of deep belief networks. *Applied Soft Computing*, 71.
- Lins, T., Oliveira, R.A.R., Correia, L.H., and Silva, J.S. (2018). Industry 4.0 retrofitting. In *2018 VIII Brazilian Symposium on Computing Systems Engineering (SBESC)*, 8–15. IEEE.
- Liu, J., Tan, C., Badrick, T., and Loh, T. (2017). Moving standard deviation and moving sum of outliers as quality tools for monitoring analytical precision. *Clinical Biochemistry*, 52.
- Sitompul, E. and Rohmat, A. (2021). IoT-based running time monitoring system for machine preventive maintenance scheduling. *ELKHA*, 13, 33.

Tong, Z.M., Xin, J.G., Tong, S.G., Yang, Z.Q., Zhao, J.Y., and Mao, J.H. (2020). Internal flow structure, fault detection, and performance optimization of centrifugal pumps. *J. Zhejiang Univ. Sci. A*, 21(2), 85–117.