

# Análise de Vibração em Máquinas Industriais com Inteligência Artificial para Previsão de Falhas e Classificação de Defeitos

Hellora Rodrigues Souza  
*Escola Politécnica e de Artes*  
*Eng. de Cont. e Automação*  
PUC Goiás  
Goiânia-GO, Brasil  
rodrigueshellora@gmail.com

José Francisco Mendes Neto  
*Escola Politécnica e de Artes*  
*Eng. de Cont. e Automação*  
PUC Goiás  
Goiânia-GO, Brasil  
josefmenandesneto@gmail.com

Wanderson Rainer H. de Araújo  
*Escola Politécnica e de Artes*  
*Orientador*  
PUC Goiás  
Goiânia-GO, Brasil  
rainer@pucgoias.edu.br

**Resumo**—Este artigo apresenta um sistema integrado de *software* e *hardware* para análise de vibrações em máquinas industriais. O objetivo principal é minimizar as paradas não planejadas e maximizar o OEE (*Overall Equipment Effectiveness*), um indicador crucial para a produtividade industrial. O sistema utiliza sensores de vibração, técnicas de inteligência artificial com aprendizado supervisionado e um dataset para classificação de possíveis defeitos. A partir da classificação, o sistema pode gerar alertas e recomendações de ações corretivas para evitar falhas e paradas não planejadas. Isso contribui para a redução de custos de manutenção, aumento da produtividade, segurança industrial e maximização do OEE.

**Palavras chave**—vibração, sensoreamento, transformada de Fourier, inteligência artificial, aprendizado supervisionado, KNN.

## I. INTRODUÇÃO

A manutenção preditiva tem se consolidado como uma estratégia crucial na indústria moderna, com o objetivo de aumentar a eficiência operacional e diminuir os custos relacionados a falhas inesperadas. Entre os métodos mais promissores nessa área está o uso de sensores de vibração para o monitoramento contínuo de máquinas industriais. A vibração atua como um indicador fundamental da condição das máquinas, fornecendo informações antecipadas sobre possíveis falhas e desgastes. Estudos anteriores ressaltam a importância do monitoramento de vibração em equipamentos industriais, destacando-o como um meio eficaz para detectar problemas antes que resultem em paradas não programadas [1] [2].

Sensores de vibração são amplamente utilizados para coletar dados em tempo real sobre o desempenho de máquinas, permitindo uma análise detalhada das condições operacionais [3]. Vibrações excessivas podem indicar desalinhamento, desbalanceamento ou desgaste de componentes internos, problemas que, se não tratados a tempo, podem levar a falhas catastróficas [4]. Esses estudos enfatizam que a detecção precoce desses problemas é essencial para minimizar o tempo de inatividade e os custos de manutenção.

A integração de dados de vibração em modelos de aprendizado supervisionado, como o K-Nearest Neighbors (KNN),

tem demonstrado resultados promissores na classificação e previsão de falhas. Métodos de aprendizado de máquina são empregados para analisar grandes volumes de dados, identificando padrões que podem não ser detectados por técnicas tradicionais [5]. Especificamente, a aplicação do KNN permite a classificação precisa de novos dados de vibração, proporcionando uma ferramenta robusta para a manutenção preditiva [6].

Um dos principais benefícios da implementação de sistemas de manutenção preditiva é a melhoria do Índice de Eficiência Global dos Equipamentos (OEE). O OEE é uma métrica abrangente que avalia a eficiência operacional, considerando disponibilidade, desempenho e qualidade [7]. Paradas não programadas impactam significativamente o OEE, reduzindo drasticamente a disponibilidade dos equipamentos e, consequentemente, a eficiência geral da produção [8]. Portanto, a capacidade de prever e prevenir essas paradas através do monitoramento contínuo de vibração representa um avanço significativo para a indústria.

Este artigo apresenta uma abordagem que integra sensores de vibração e a técnica de aprendizado supervisionado KNN para a manutenção preditiva de máquinas industriais. Os dados de vibração capturados pelos sensores são processados e integrados em um dataset, que serve como base para o treinamento do modelo de IA. Com base nesse dataset, a IA pode receber e classificar novos dados, identificando possíveis problemas nas máquinas antes que falhas inesperadas ocorram. Essa metodologia permite a realização de manutenção preditiva, evitando paradas não programadas e contribuindo significativamente para a melhoria do OEE.

## II. REVISÃO DA LITERATURA

Considerando a positiva contribuição que um sistema antecipativo proporciona, especialmente para máquinas industriais de forma a potencializar a OEE, a comunidade científica tem empregado esforços em projetos e desenvolvimentos de sistemas capazes de analisar a vibração em máquinas industriais de forma a antecipar falhas e minimizar paradas não programadas.

Como exemplo, em [9] é proposto um sistema de detecção de anomalias baseado em *deep learning* para máquinas industriais. Usando análise de vibrações, o sistema identifica defeitos em componentes de turbinas eólicas, como caixas de engrenagens. A abordagem utiliza um autoencoder de seis camadas, que demonstrou alta precisão na detecção de falhas, alcançando uma acurácia de 91%.

Os autores em [10] fornecem um tutorial abrangente sobre métodos de processamento de sinais para manutenção baseada em condição via análise de vibrações. Eles destacam técnicas para diagnóstico de rolamentos e engrenagens, incluindo métodos como deconvolução de entropia mínima para realçar assinaturas de falhas e resampling angular para análise de sinais de vibração.

Em [11] são revisadas abordagens baseadas em modelos e dados para detecção de falhas em processos industriais. São destacadas as necessidades de métodos híbridos que integrem diagnósticos baseados em modelos com procedimentos inteligentes, visando melhorar a previsão de falhas e evitar riscos de segurança. A pesquisa foca em estratégias de manutenção preditiva que utilizam análise de vibrações para monitorar e diagnosticar a saúde das máquinas em tempo real.

No artigo apresentado em [12], são destacadas metodologias de monitoramento de condição baseada em vibrações para diagnósticos de máquinas rotativas. O artigo analisa técnicas de processamento de sinais, seleção de características e diagnóstico de falhas, destacando as tendências e inovações significativas na área. É um recurso abrangente para entender os métodos aplicados em diferentes fases do processo de monitoramento.

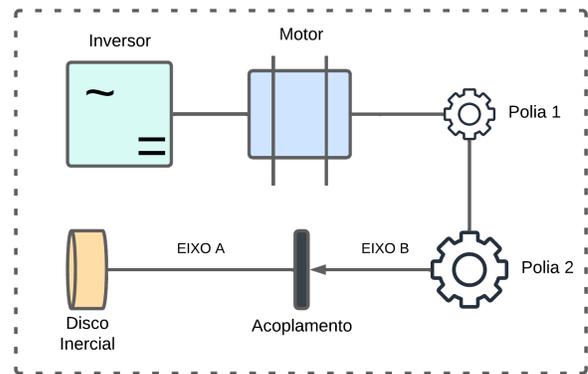
Por fim, em [13] é abordado a crescente utilização de motores lineares elétricos na automação industrial, destacando suas vantagens em desempenho dinâmico, confiabilidade e flexibilidade na geração de trajetórias. Entretanto, os rolamentos lineares, que conectam a parte móvel à parte fixa do motor, são vulneráveis ao desgaste e à contaminação ambiental, um problema mais acentuado em comparação aos rolamentos rotativos radiais. Para mitigar esses desafios, o artigo propõe um método de diagnóstico baseado na análise de vibrações, visando identificar assinaturas específicas relacionadas a falhas nos rolamentos lineares, contribuindo para a manutenção preditiva e a redução de paradas inesperadas.

### III. METODOLOGIA

Para implementação das análises de vibração apresentadas neste artigo, foi empregada uma plataforma experimental para análise de defeitos. A Fig. 1 ilustra um diagrama em blocos da plataforma empregada para os estudos apresentados neste artigo.

Conforme pode ser observado na Fig. 1, a plataforma conta com um motor elétrico cuja velocidade pode ser variada pelo inversor de frequência disponível na bancada. A energia mecânica do eixo do motor é transferida entre duas polias via correia. A segunda polia é integrada a um eixo cujo acoplamento coloca como carga do motor um disco inercial.

Fig. 1: Diagrama em blocos da plataforma experimental utilizada.

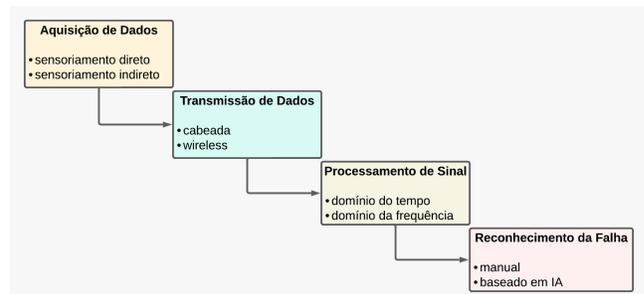


Dessa forma, esta plataforma experimental permite, além da variação de velocidade do motor:

- analisar o comportamento do sistema perante o desalinhamento de eixo. Neste caso, o **EIXO A** e o **EIXO B** podem ser desalinhados através do acoplamento;
- analisar o comportamento do sistema perante o desbalanceamento de carga. O disco inercial possui um conjunto de parafusos que podem ser removidos individualmente, permitindo desbalancear a carga mecânica acoplada ao eixo do motor.

A plataforma ilustrada no diagrama da Fig. 1 permite outras modalidades de ensaio. Porém neste trabalho foram empregados apenas os testes de desalinhamento de eixo e desbalanceamento de carga. A Fig. 2 ilustra o fluxograma dos passos seguidos na aplicação da solução.

Fig. 2: Fluxograma das etapas.



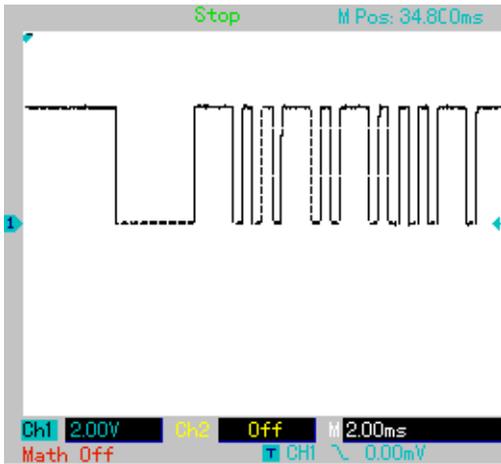
A aquisição de dados é feita por sensoriamento e a transmissão é cabeadada. Os dados são transformados do domínio do tempo para o domínio da frequência e, por fim, há o reconhecimento e classificação dos defeitos por meio da inteligência artificial.

Em relação ao sensoriamento, inicialmente foi empregado um sensor eletromecânico. Este sensor possui um contato reversível que se movimenta conforme a vibração da superfície na qual o mesmo é instalado. Dessa forma, este sensor, em conjunto com um circuito comparador interno, proporciona em

sua saída uma forma de onda quadrada, conforme o contato se abre e se fecha com a vibração. A Fig. 3 ilustra a forma de onda proporcionada pelo sensor eletromecânico.

Conforme pode ser observado na Fig. 3, as informações proporcionadas por este tipo de sensor são limitadas, pois os únicos parâmetros que se alteram com a vibração são a frequência e/ou a razão cíclica do sinal de saída, o que pode ser um fator limitador para identificar o tipo de falha no sistema. Alguns trabalhos na comunidade científica empregam este tipo de sensor com medição do valor RMS (*root mean square*) da vibração, como apresentado em [13] e em [14].

Fig. 3: Forma de onda proporcionada por sensor de vibração eletro.



Neste caso, cada ponto  $x_a$  do sinal de saída é submetido à equação:

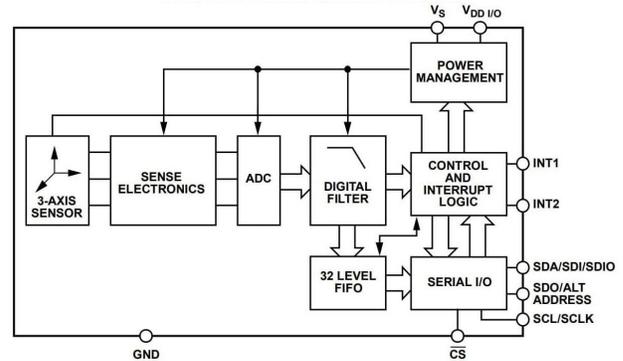
$$V_{RMS} = \sqrt{\frac{1}{N} \sum_{0}^{N-1} x_a^2} \quad (1)$$

Onde  $N$  é o número de pontos empregados na análise do valor RMS. Este valor é uma indicação quantitativa da potência do sinal de vibração, mas não possibilita identificar maiores características da vibração a ponto de indicar se a vibração é decorrente de desalinhamento de eixo ou desbalanceamento de carga, objetivo deste estudo.

Dessa forma, o sensor eletromecânico foi substituído por um sensor do tipo acelerômetro. Este tipo de sensor permite a medição de aceleração nas três dimensões:  $x$ ,  $y$  e  $z$ . A Fig. 4 ilustra o diagrama em blocos do sensor acelerômetro empregado.

O sensor acelerômetro mede a aceleração, medida em  $g$  (gravidade), e disponibiliza os valores medidos via comunicação i2C (*Inter-Integrated Circuit*), conforme ilustra o diagrama da Fig. 4, extraído do datasheet do sensor. Ou seja, o sensor obtém os valores de aceleração nas três dimensões e disponibiliza estes valores via comunicação. Isto impacta no período de amostragem do sensor, uma vez que um tempo é

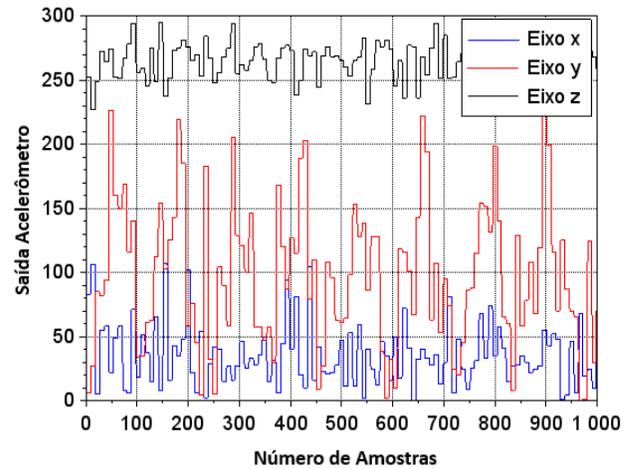
Fig. 4: Diagrama de blocos do sensor acelerômetro (extraído do datasheet do sensor).



gasto no processo de obtenção dos valores em  $g$  e no processo de enviar os valores via i2C.

A Fig. 5 ilustra um exemplo de gráfico referente aos valores de aceleração dos eixos  $x$ ,  $y$  e  $z$  proporcionados pelo sensor acelerômetro. Neste gráfico, o eixo horizontal é o número de amostras, e o eixo vertical a aceleração em  $\pm g$ .

Fig. 5: Exemplo de sinal de saída do sensor acelerômetro.



Observando o tipo de gráfico proporcionado pelo sensor acelerômetro, é possível constatar que mais informações são proporcionadas pelo sensor em comparação com o sensor eletromecânico utilizado anteriormente. Ao passo que o sensor eletromecânico proporciona sinais que têm sua frequência e razão cíclica variadas com a vibração, o sensor acelerômetro indica um sinal temporal de vibração em  $\pm g$ . Após vários testes na plataforma experimental, foi constatado que a frequência gerada é de aproximadamente 500 Hz. Pelo teorema de Nyquist, a frequência de amostragem do sensor deve ser de, pelo menos, 1000 Hz, característica atendida pelo sensor acelerômetro. Contudo, para extrair a identidade de cada tipo de vibração referente a defeitos como desalinhamento de eixo ou desbalanceamento de carga, os sinais de

saída do sensor acelerômetro foram submetidos a uma análise matemática, especificamente, a FFT (*Fast Fourier Transform*).

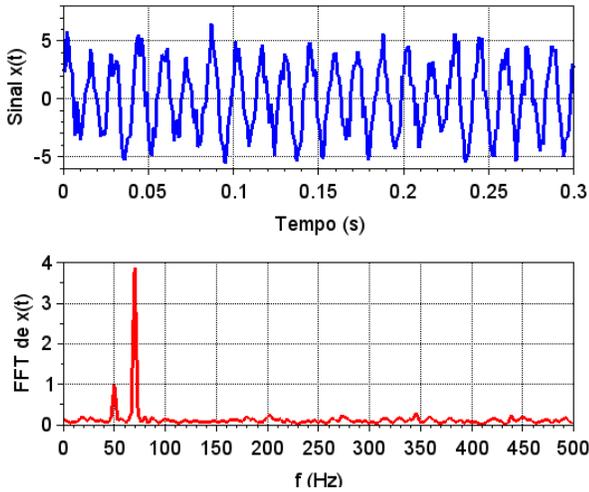
Para uma sequência  $x(n)$  finita, com  $N$  pontos provenientes do sensor acelerômetro, tais que os pontos  $x(n)$  não são definidos fora do intervalo  $0 \leq n \leq N - 1$ . A DFT (*Discrete Fourier Transform*) desse sinal é expressa por:

$$X(k) = \sum_0^{N-1} x(n) \cdot e^{-j2\pi kn/N} \quad (2)$$

Esta equação permite calcular a contribuição da  $k$ -ésima frequência para cada ponto  $x(n)$  do sinal do sensor. Dessa forma, é possível obter maiores características do sinal para posteriormente identificar o perfil de vibração, tornando possível a classificação do possível defeito.

A aplicação da Eq. 2, para  $N$  pontos, requer  $N \times N$  cálculos. Para minimizar o esforço computacional no tratamento dos sinais sensoriais, foi empregada a FFT, que requer apenas  $N \cdot \log(N)$  operações, reduzindo o tempo para obter a amplitude para as  $k$  frequências em cada ponto. Apesar da perda de dados devido aos cálculos mais rápidos, não houveram alterações significativas nos resultados a ponto de desconsiderar o uso da DFT [15]. Para realizar os cálculos foram utilizadas as plataformas SciLab e VScode (Python).

Fig. 6: Exemplo de um sinal temporal  $x(t)$  e sua respectiva FFT (módulo).



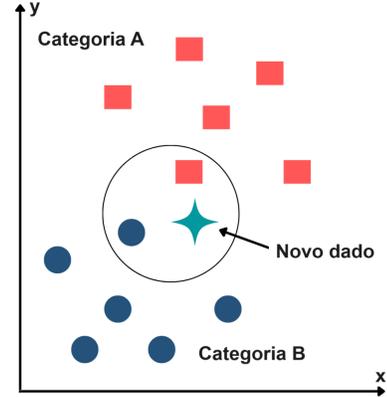
A Fig. 6 apresenta valores absolutos para as  $X(k)$  frequências dos dados do acelerômetro, uma vez que, conforme pode ser observado na Eq. 2, cada valor  $X(k)$  é um número complexo. Logo, o gráfico inferior da Fig. 6 (FFT) apresenta um perfil mais completo da identidade do sinal de vibração, permitindo classificar um possível defeito como desalinhamento de eixo ou desbalanceamento de carga.

Embora o perfil da FFT não seja exatamente o mesmo para diferentes ensaios, cada sinal referente a um tipo de falha possui uma identidade, que pode ser utilizado para construção

de um dataset de forma a possibilitar futuras classificações. Isso é feito por um sistema de inteligência artificial com aprendizagem supervisionada, onde os valores do dataset são rotulados, conforme exposto em [16].

Entre os vários algoritmos para classificação e regressão em métodos de aprendizado supervisionado, destaca-se o KNN. O algoritmo KNN agrupa os dados em subconjuntos coerentes e classifica os dados recém-inseridos com base em sua semelhança com dados previamente treinados, conforme ilustra a Fig. 7 [17].

Fig. 7: Ilustração do processo de classificação.



A entrada é atribuída à classe com a qual compartilha os vizinhos mais próximos (*nearest neighbors*). A distância entre novos pontos e os pontos do dataset é calculada considerando a distância euclidiana:

$$d_n = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (3)$$

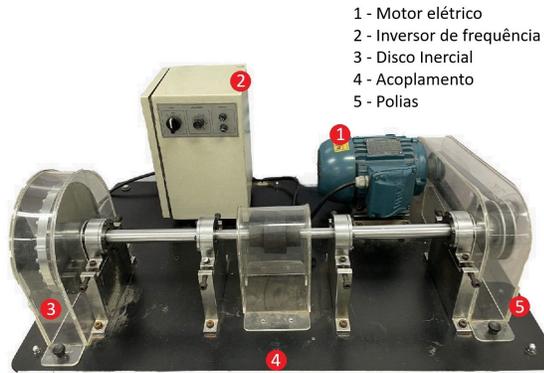
Ou seja, o KNN é um algoritmo de aprendizado supervisionado utilizado para classificação e regressão, baseado na premissa de que objetos semelhantes estão próximos uns dos outros. A técnica envolve a determinação dos  $K$  vizinhos mais próximos de um novo dado, com base na distância entre este dado e os dados do conjunto de treinamento. Para classificação, o rótulo do novo dado é determinado pela maioria dos rótulos dos  $K$  vizinhos mais próximos. Na regressão, o valor do novo dado é calculado como a média dos valores dos  $K$  vizinhos mais próximos. A simplicidade e a eficácia do KNN o tornam uma escolha popular em diversas aplicações de reconhecimento de padrões e mineração de dados.

#### IV. RESULTADOS OBTIDOS

Conforme exposto anteriormente, os testes foram realizados em plataforma experimental, cujo diagrama é apresentado na Fig. 1. A Fig. 8 apresenta uma fotografia da plataforma experimental, bem como a Fig. 9.

Os pontos marcados em vermelho na Fig. 8 são pontos onde o sensor eletromecânico foi instalado de forma que o valor RMS de vibração pudesse ser coletado. Logo, para cada um dos pontos indicados, o ponto 1 (motor) foi o ponto que

Fig. 8: Fotografia da plataforma experimental.



expressou maior vibração, além de ser o ponto crítico de falhas para a plataforma.

Os demais testes realizados consistiram de remover os parafusos do disco inercial apresentado na Fig. 9 de forma a provocar o defeito de desbalanceamento de carga. Além disso, o eixo foi desalinhado no ponto 4 da Fig. 8 de forma a provocar o defeito de desalinhamento.

Fig. 9: Fotografia da plataforma experimental com destaque do disco inercial.



O sensor eletromecânico empregado foi o sensor SW-240. Como exposto anteriormente, devido à escassez de informações sobre as características de vibração proporcionadas pelo sensor SW-240, optou-se por empregar um sensor o tipo acelerômetro. O modelo utilizado nesse trabalho foi o ADXL345. A Fig. 10 apresenta a figura de ambos os sensores citados.

Foi estabelecida uma sequência de ensaios para a

Fig. 10: Fotografia dos sensores de vibração utilizados.



plataforma experimental, conforme apresentado na Tab. I. Estes ensaios foram feitos de forma a gerar a base de dados para implementação do KNN para novos dados, de forma que o sistema possa identificar esse novo dado de vibração como eixo desalinhado, carga desbalanceada ou simplesmente uma variação de velocidade não prevista. Desta forma, foram estabelecidos 12 cenários.

Tab. I: Ensaios programados para geração do dataset.

EIXO	CARGA	VELOCIDADE	RÓTULO
Desalinhado	Balanceada	Baixa (30% - 525 rpm)	1
Desalinhado	Balanceada	Média (50% - 875 rpm)	2
Desalinhado	Balanceada	Alta (70% - 1225 rpm)	3
Desalinhado	Desbalanceada	Baixa	4
Desalinhado	Desbalanceada	Média	5
Desalinhado	Desbalanceada	Alta	6
Alinhado	Desbalanceada	Baixa	7
Alinhado	Desbalanceada	Média	8
Alinhado	Desbalanceada	Alta	9
Alinhado	Balanceada	Baixa	10
Alinhado	Balanceada	Média	11
Alinhado	Balanceada	Alta	12

Para potencializar o dataset, cada rótulo da Tab. I foi ensaiado três vezes, de forma a se obter mais dados para o aprendizado. Foram coletados 1000 pontos em x, 1000 em y e 1000 em z para cada rótulo, totalizando 36000 pontos. De todo o dataset, 70% foi utilizado para treinamento e 30% para testes e validação. Cada ensaio captura os dados provenientes do sensor ADXL345 e faz a FFT desses sinais, obtendo um perfil de frequências conforme ilustrado na Fig.6.

Para validação do sistema de aprendizado e classificação desenvolvido, foram observados os valores de:

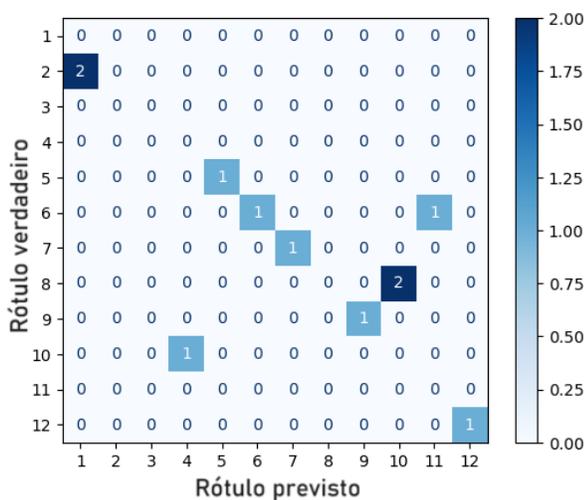
- **TP (True Positive):** referem-se ao número de instâncias que foram corretamente classificadas como pertencentes à classe positiva;
- **TN (True Negative):** são as instâncias que foram corretamente identificadas como pertencentes à classe negativa;
- **FP (False Positive):** ocorrem quando instâncias da classe negativa são incorretamente classificadas como pertencentes à classe positiva;
- **FN (False Negative):** são instâncias da classe positiva incorretamente classificadas como negativas.

Os valores de TP, TN, FP e FN são métricas fundamentais utilizadas para avaliar o desempenho de algoritmos

de classificação. Essas métricas são essenciais para calcular outras medidas de performance, como precisão (a proporção de instâncias verdadeiramente positivas dentre as classificadas como positivas), sensibilidade ou recall (a proporção de instâncias positivas corretamente identificadas), especificidade (a proporção de instâncias negativas corretamente identificadas), e a F1-Score (a média harmônica entre precisão e recall). Ao aplicar o KNN, essas métricas permitem uma compreensão detalhada de como o algoritmo está classificando corretamente ou erroneamente as instâncias, proporcionando uma visão clara sobre a eficácia e robustez do modelo em diferentes cenários.

A Fig. 11 apresenta a matriz de confusão do aprendizado supervisionado desenvolvido para o projeto.

Fig. 11: Matriz de confusão para o KNN implementado.



A matriz de confusão é uma ferramenta de avaliação que fornece uma visão detalhada do desempenho de um algoritmo de classificação. Ela é uma tabela de contingência que permite visualizar o número de previsões corretas e incorretas feitas pelo modelo, organizadas por cada classe. A matriz possui quatro componentes principais para cada classe: TP, TN, FP e FN. Esses componentes ajudam a identificar a precisão do modelo (taxa de acertos), a precisão de previsão de cada classe e a capacidade do modelo de distinguir entre as classes. Com a matriz de confusão, é possível calcular métricas importantes como acurácia, precisão, recall, especificidade e F1-Score. Essas métricas fornecem uma visão completa sobre onde o modelo KNN está acertando e errando, permitindo ajustes e melhorias na sua implementação. Além disso, a matriz de confusão é especialmente útil para identificar se há algum viés nas previsões do modelo, como a tendência de prever excessivamente uma classe em detrimento de outra.

Os rótulos verdadeiros estão no eixo vertical, os rótulos previstos no eixo horizontal e a diagonal principal representa as previsões corretas. Já as demais precisões, por mais que sejam

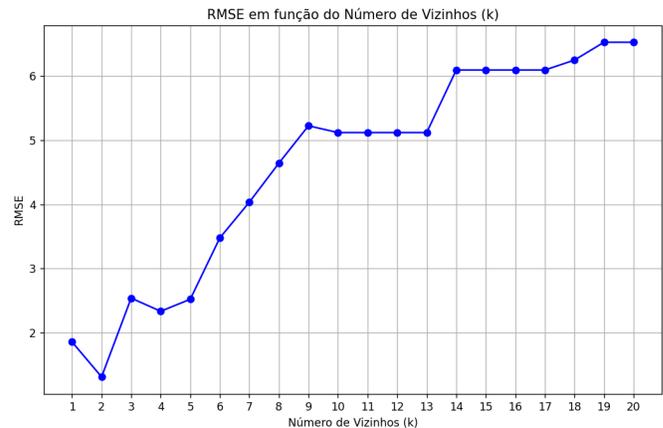
equivocadas, não comprometeram a acurácia de identificação e classificação do método.

A matriz de confusão ilustrada na Fig. 11 foi obtida adotando  $k = 3$ , ou seja, 3 vizinhos mais próximos ao novo dado. Este valor foi escolhido considerando a evolução do RMSE (valor RMS do erro), o qual pode ser observado na Fig.12 em função do valor de  $k$ . A fórmula do valor RMS do erro é expressa por:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(Y_i - P_i)^2}{n}} \quad (4)$$

Na Fig.12 é possível observar que o RMSE aumenta com o valor de  $k$ . Contudo, para valores de  $k$  iguais a 3 ou 5, o RMSE permanece inalterado. Logo, o valor de  $k = 3$  foi escolhido por proporcionar melhor acurácia, conforme será apresentado a seguir. Os valores pares de  $k$  foram desconsiderados pois tais valores podem resultar em empate de rótulos durante a aplicação do KNN.

Fig. 12: Evolução do RMSE em função de  $k$ .



De posse dos valores indicados na Tab. I, foi possível determinar a acurácia  $AC$  com a qual o método poderia identificar defeitos de desalinhamento de eixo e desbalanceamento de carga.

A acurácia, que representa a proporção de instâncias corretamente classificadas pelo classificador, pode ser obtida como:

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

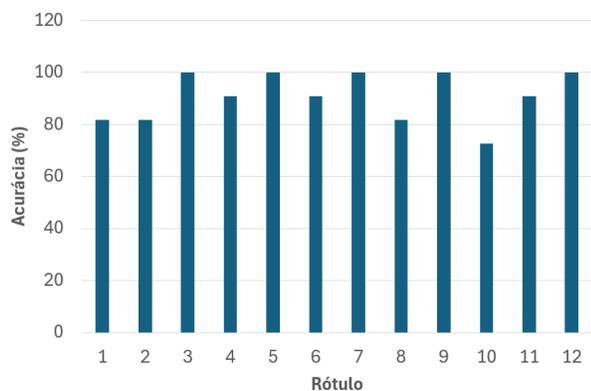
Logo, para os 12 rótulos dos ensaios indicados na Tab. I, foram obtidos os valores de acurácia indicados na Fig. 13.

Analisando a Fig. 13, percebe-se que o sistema possui acurácia elevada para as classes, com exceção do rótulo 10, que ficou com acurácia de 72,7%, a menor entre todas.

## V. CONCLUSÕES

Neste artigo, foi demonstrada a eficácia da aplicação da técnica de aprendizado supervisionado *K-Nearest Neighbors* (KNN) na detecção e classificação de defeitos em uma

Fig. 13: Acurácia para detecção de defeitos para cada rótulo.



plataforma experimental. A plataforma, composta por motor, inversor, correia, eixo e carga, foi equipada com sensores de vibração para coletar dados essenciais. O uso do sensor acelerômetro ADXL345 permitiu a medição precisa das acelerações nos eixos x, y e z. A Transformada Rápida de Fourier (FFT) foi aplicada aos dados coletados para criar um dataset robusto.

Os resultados da classificação, representados pelos índices de acurácia para doze rótulos distintos, indicaram valores de de pelo menos 81,8%, com exceção de uma das classes. Esses índices demonstram que o modelo KNN foi capaz de identificar e classificar com alta precisão defeitos como desalinhamento de eixo, desbalanceamento de carga e variação de velocidade em diferentes condições operacionais.

A metodologia apresentada não só validou o uso de sensores de vibração e técnicas de aprendizado de máquina como ferramentas eficazes para manutenção preditiva, mas também evidenciou seu potencial para melhorar significativamente o Índice de Eficiência Global dos Equipamentos (OEE). A implementação de tal sistema permite a detecção precoce de problemas, possibilitando a realização de manutenção preditiva e evitando paradas não programadas. Consequentemente, essa abordagem contribui para a eficiência operacional e a redução de custos de manutenção na indústria.

Em resumo, este estudo comprova que a integração de sensores de vibração com algoritmos de aprendizado de máquina, especificamente o KNN, é uma solução promissora para a manutenção preditiva em ambientes industriais, assegurando maior confiabilidade e desempenho dos equipamentos.

Uma possível linha para continuidade deste trabalho seria o estudo e análise do momento correto para a parada de máquina. Desta forma, a aplicação da previsão e realização da manutenção preditiva são aprimoradas.

## REFERÊNCIAS

[1] Romanssini, M.; de Aguirre, P.C.C.; Compassi-Severo, L.; Girardi, A.G. A Review on Vibration Monitoring Techniques for Predictive Maintenance of Rotating Machinery. *Eng* 2023, 4, 1797-1817. <https://doi.org/10.3390/eng4030102>

[2] Mey, O.; Schneider, A.; Enge-Rosenblatt, O.; Mayer, D.; Schmidt, C.; Klein, S.; Herrmann, H.-G. Condition Monitoring of Drive Trains by Data Fusion of Acoustic Emission and Vibration Sensors. *Processes* 2021, 9, 1108. <https://doi.org/10.3390/pr9071108>

[3] Ghazali, M.H.M., Rahiman, W. (2022). Real-Time Vibration Monitoring Using MEMS Vibration Sensors. In: Mahyuddin, N.M., Mat Noor, N.R., Mat Sakim, H.A. (eds) Proceedings of the 11th International Conference on Robotics, Vision, Signal Processing and Power Applications. Lecture Notes in Electrical Engineering, vol 829. Springer, Singapore. [https://doi.org/10.1007/978-981-16-8129-5\\_56](https://doi.org/10.1007/978-981-16-8129-5_56)

[4] Billel Bengherbia, Mohamed Ould Zmirli, Abdelmoghni Toubal, Abderrezak Guessoum, FPGA-based wireless sensor nodes for vibration monitoring system and fault diagnosis, *Measurement*, Volume 101, 2017, Pages 81-92, ISSN 0263-2241, <https://doi.org/10.1016/j.measurement.2017.01.022>.

[5] Ucar, A.; Karakose, M.; Kırımça, N. Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends. *Appl. Sci.* 2024, 14, 898. <https://doi.org/10.3390/app14020898>

[6] A. Bouguerne, A. Lebaroud, A. Medoued and A. Boukadoum, "Classification of induction machine faults by K-nearest neighbor," 2011 7th International Conference on Electrical and Electronics Engineering (ELECO), Bursa, Turkey, 2011, pp. I-363-I-366.

[7] J. Kinauer and B. Müller, "Hidden equipment productivity opportunities," 25th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC 2014), Saratoga Springs, NY, USA, 2014, pp. 165-168, doi: 10.1109/ASMC.2014.6846990.

[8] Amar Prem, K. (2021). Implementation of Production Planning Using Overall Equipment Efficiency (OEE) for IIoT. In: Jeena Jacob, I., Kolandapalayam Shanmugam, S., Piramuthu, S., Falkowski-Gilski, P. (eds) Data Intelligence and Cognitive Informatics. Algorithms for Intelligent Systems. Springer, Singapore. [https://doi.org/10.1007/978-981-15-8530-2\\_68](https://doi.org/10.1007/978-981-15-8530-2_68)

[9] Ahmed, I.; Ahmad, M.; Chehri, A.; Jeon, G. A Smart-Anomaly-Detection System for Industrial Machines Based on Feature Autoencoder and Deep Learning. *Micromachines* 2023, 14, 154. <https://doi.org/10.3390/mi14010154>

[10] Matania, O.; Bachar, L.; Bechhoefer, E.; Bortman, J. Signal Processing for the Condition-Based Maintenance of Rotating Machines via Vibration Analysis: A Tutorial. *Sensors* 2024, 24, 454. <https://doi.org/10.3390/s24020454>

[11] Mercorelli, P. Recent Advances in Intelligent Algorithms for Fault Detection and Diagnosis. *Sensors* 2024, 24, 2656. <https://doi.org/10.3390/s24082656>

[12] Kafeel, A.; Aziz, S.; Awais, M.; Khan, M.A.; Afaq, K.; Idris, S.A.; Alshazly, H.; Mostafa, S.M. An Expert System for Rotating Machine Fault Detection Using Vibration Signal Analysis. *Sensors* 2021, 21, 7587. <https://doi.org/10.3390/s21227587>

[13] C. Bianchini, F. Immovilli, M. Cocconcelli, R. Rubini and A. Bellini, "Fault Detection of Linear Bearings in Brushless AC Linear Motors by Vibration Analysis," in *IEEE Transactions on Industrial Electronics*, vol. 58, no. 5, pp. 1684-1694, May 2011, doi: 10.1109/TIE.2010.2098354.

[14] Joel Igba, Kazem Alemzadeh, Christopher Durugbo, Egill Thor Eiriksson, Analysing RMS and peak values of vibration signals for condition monitoring of wind turbine gearboxes, *Renewable Energy*, Volume 91, 2016, Pages 90-106, ISSN 0960-1481, <https://doi.org/10.1016/j.renene.2016.01.006>.

[15] K. Li, W. Zheng and K. Li, "A Fast Algorithm With Less Operations for Length-N=q×2m DFTs," in *IEEE Transactions on Signal Processing*, vol. 63, no. 3, pp. 673-683, Feb.1, 2015, doi: 10.1109/TSP.2014.2379678.

[16] M. A. El Mrabet, K. El Makkaoui and A. Faize, "Supervised Machine Learning: A Survey," 2021 4th International Conference on Advanced Communication Technologies and Networking (CommNet), Rabat, Morocco, 2021, pp. 1-10, doi: 10.1109/CommNet52204.2021.9641998.

[17] K. Taunk, S. De, S. Verma and A. Swetapadma, "A Brief Review of Nearest Neighbor Algorithm for Learning and Classification," 2019 International Conference on Intelligent Computing and Control Systems (ICCS), Madurai, India, 2019, pp. 1255-1260, doi: 10.1109/ICCS45141.2019.9065747.