

Análise comparativa de acelerômetros MEMS de baixo custo para detecção de falhas em rolamentos usando redes neurais convolucionais

Diogo S. Almeida¹, João V. Pelegrino¹, Cristiano A. Pessoa¹,
Rogério D. Dantas¹, Wilson C. S. Junior¹

¹Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP)
Campus Guarulhos
Guarulhos – SP – Brasil

diogo.almeida@aluno.ifsp.edu.br, pelegrino.jv@gmail.com,
cristianopessoa@ifsp.edu.br, rogerio.dantas@ifsp.edu.br,
wilsoncarlos@ifsp.edu.br

Abstract. *Predictive maintenance is essential for ensuring the reliability of rotating machinery, in which bearing failures are among the most common issues. This work evaluates the use of low-cost MEMS accelerometers for fault detection using Convolutional Neural Networks (CNNs). Vibration signals were acquired at 200 RPM under three conditions: normal operation, rolling element fault, and inner race fault. After preprocessing, the data were converted into 8×8 matrices to be used as input for the CNN model. The proposed model achieved approximately 94.76% in accuracy, precision, and recall. The results demonstrate the feasibility of the proposed approach for low-cost predictive maintenance applications.*

Resumo. *A manutenção preditiva é essencial para a confiabilidade de máquinas rotativas, nas quais falhas em rolamentos são frequentes. Este trabalho avalia o uso de acelerômetros MEMS de baixo custo na detecção de falhas por meio de Redes Neurais Convolucionais (CNNs). Os sinais de vibração foram coletados a 200 RPM em três condições: normal, falha no elemento rolante e falha na pista interna. Após pré-processamento, os dados foram convertidos em matrizes 8×8 para entrada na CNN. O modelo alcançou aproximadamente 94,76 de acurácia, precisão e recall. Os resultados demonstram a viabilidade da abordagem para manutenção preditiva de baixo custo.*

A crescente demanda por alta disponibilidade, confiabilidade e eficiência em sistemas industriais tem impulsionado a adoção de estratégias avançadas de manutenção. Nesse contexto, a manutenção preditiva (PdM) tem se destacado como uma abordagem eficaz para reduzir custos operacionais, minimizar paradas não planejadas e aumentar a vida útil dos equipamentos [Romanssini et al. 2023]. Em ambientes industriais modernos, os custos de manutenção podem representar entre 15% e 60% do custo total de produção, evidenciando a importância de técnicas eficientes de monitoramento de condição [Romanssini et al. 2023].

Máquinas rotativas, como motores elétricos, bombas e compressores, são amplamente utilizadas em processos industriais e estão sujeitas a falhas decorrentes do desgaste progressivo de seus componentes [Zhu et al. 2023]. Entre esses componentes, os rolamentos são particularmente críticos, sendo responsáveis por uma parcela significativa das falhas mecânicas, podendo atingir cerca de 40% dos casos em motores elétricos [Hakim et al. 2023]. Dessa forma, o diagnóstico precoce de falhas em rolamentos é essencial para evitar perdas econômicas e riscos operacionais.

A análise de vibração destaca-se como uma das principais técnicas de monitoramento de condição em máquinas rotativas, devido à sua natureza não invasiva e à sua capacidade de detectar alterações no comportamento dinâmico do sistema [Romanssini et al. 2023]. Variações nos padrões de vibração, como mudanças na amplitude ou frequência do sinal, podem indicar a presença de falhas como desalinhamento, desbalanceamento ou defeitos em rolamentos [Romanssini et al. 2023]. Contudo, a análise desses sinais é desafiadora devido à sua natureza não estacionária e à presença de ruídos e interferências externas [Hakim et al. 2023].

Tradicionalmente, sistemas de monitoramento de vibração utilizam acelerômetros piezoelétricos de alto desempenho, que apresentam elevada sensibilidade e precisão. Entretanto, o alto custo desses sensores constitui uma barreira significativa para a implementação em larga escala de sistemas de manutenção preditiva, especialmente em aplicações distribuídas ou de baixo custo [Ompusunggu et al. 2021]. Nesse cenário, acelerômetros baseados em Sistemas Microeletromecânicos (MEMS) têm emergido como uma alternativa promissora, oferecendo vantagens como baixo custo, baixo consumo de energia e facilidade de integração em sistemas embarcados [Sharma et al. 2024].

Paralelamente, o avanço das técnicas de aprendizado de máquina e aprendizado profundo tem transformado o diagnóstico de falhas em sistemas mecânicos [Zhang et al. 2020]. Abordagens baseadas em dados, especialmente aquelas que utilizam Redes Neurais Convolucionais (CNNs), têm demonstrado alta capacidade de extrair automaticamente características relevantes a partir de sinais de vibração, reduzindo a dependência de técnicas tradicionais de engenharia de atributos [Zhao et al. 2025]. Essas redes são particularmente eficazes na análise de sinais complexos e não lineares, sendo amplamente utilizadas em tarefas de classificação de falhas em rolamentos [Lu et al. 2017].

Diante desse contexto, este trabalho tem como objetivo avaliar e comparar o desempenho de acelerômetros MEMS de baixo custo na detecção de falhas em rolamentos de rolo, utilizando Redes Neurais Convolucionais. O estudo foca na análise do sensor MMA7361 na aquisição de sinais de vibração sob condições controladas de operação, considerando três estados distintos: rolamento em condição normal, falha no elemento rolante e falha na pista.

Adicionalmente, propõe-se o desenvolvimento de um *pipeline* completo de processamento de sinais, incluindo etapas de pré-processamento, segmentação e transformação dos dados em representações bidimensionais adequadas para entrada em modelos de CNN. O desempenho dos modelos será avaliado por meio de métricas como acurácia, precisão e recall, com o objetivo de verificar a viabilidade técnica da utilização de sensores de baixo custo em sistemas de manutenção preditiva.

1. Trabalhos Relacionados

O diagnóstico de falhas em rolamentos tem sido amplamente investigado na literatura, especialmente no contexto de manutenção preditiva em máquinas rotativas [Hakim et al. 2023, Zhao et al. 2025]. As abordagens existentes podem ser divididas, de forma geral, em três categorias principais: técnicas baseadas em análise de vibração, uso de sensores MEMS de baixo custo e aplicação de modelos de aprendizado profundo, em especial Redes Neurais Convolucionais (CNNs).

1.1. Detecção de falhas em rolamentos

A detecção de falhas em rolamentos é tradicionalmente realizada por meio da análise de sinais de vibração, devido à forte correlação entre o estado mecânico do componente e o comportamento dinâmico do sistema [Romanssini et al. 2023]. Técnicas clássicas de processamento de sinais, como a Transformada Rápida de Fourier (FFT), a Transformada Wavelet e a análise de envelope, são amplamente utilizadas para a extração de características relevantes associadas a diferentes tipos de falhas [Hakim et al. 2023].

Entretanto, em ambientes industriais reais, os sinais de vibração apresentam natureza não estacionária e são frequentemente contaminados por ruídos e interferências externas, o que dificulta a identificação precisa de padrões característicos de falha [Hakim et al. 2023]. Além disso, abordagens tradicionais dependem fortemente de conhecimento especializado para a definição de atributos, o que limita sua capacidade de generalização em diferentes condições operacionais [Zhu et al. 2023].

Diante dessas limitações, o aumento da complexidade dos sistemas industriais e da disponibilidade de grandes volumes de dados tem impulsionado o uso de abordagens baseadas em dados, permitindo a automação do processo de diagnóstico e maior robustez frente a variações operacionais [Zhang et al. 2020].

1.2. Uso de acelerômetros MEMS no monitoramento de condição

O uso de acelerômetros baseados em Sistemas Microeletromecânicos (MEMS) em aplicações de monitoramento de condição tem crescido significativamente nos últimos anos, impulsionado pela demanda por soluções de baixo custo, escaláveis e de fácil integração em sistemas embarcados [Ompusunggu et al. 2021]. Esses sensores apresentam vantagens como reduzido consumo de energia, dimensões compactas e viabilidade de implantação em arquiteturas distribuídas de monitoramento [Sharma et al. 2024].

Estudos recentes indicam que acelerômetros MEMS podem ser empregados com sucesso na detecção de falhas em sistemas mecânicos, apresentando desempenho competitivo em relação a sensores piezoelétricos em determinadas condições operacionais [Ompusunggu et al. 2021]. No entanto, esses sensores ainda apresentam limitações relevantes, como maior densidade de ruído, menor faixa dinâmica e sensibilidade a variações ambientais, fatores que podem comprometer a qualidade dos sinais adquiridos [Sharma et al. 2024].

1.3. Aplicação de CNNs em análise de vibração

Nos últimos anos, o uso de aprendizado profundo tem revolucionado o diagnóstico de falhas em sistemas mecânicos [Zhao et al. 2025, Zhang et al. 2020]. Entre os diversos

modelos, as Redes Neurais Convolucionais (CNNs) têm se destacado devido à sua capacidade de extrair automaticamente características relevantes a partir de dados brutos, reduzindo a necessidade de engenharia manual de atributos [Lu et al. 2017].

CNNs têm sido amplamente aplicadas na análise de sinais de vibração, tanto em sua forma original (1D) quanto após transformações para representações bidimensionais, como espectrogramas ou matrizes reorganizadas [Sinkittayanont and Ratanasumawong 2024]. Essas abordagens permitem capturar padrões complexos no domínio tempo-frequência, aumentando a precisão na classificação de falhas.

Além disso, estudos recentes têm explorado a utilização de arquiteturas leves de CNN para implementação em dispositivos embarcados, possibilitando diagnósticos em tempo real com baixo consumo computacional [Tan and Wannaboon 2026]. Essa tendência está alinhada com o avanço de tecnologias como TinyML, que viabilizam a execução de modelos de aprendizado profundo diretamente na borda, reduzindo latência e dependência de infraestrutura em nuvem [Abadade et al. 2023].

1.4. Lacunas na literatura

Apesar dos avanços observados, algumas lacunas ainda permanecem na literatura [Zhao et al. 2025]. A maior parte dos estudos concentra-se no uso de sensores de alto desempenho ou em bases de dados públicas, o que pode limitar a representatividade dos resultados em cenários reais de aplicação industrial.

Além disso, ainda são escassos os trabalhos que investigam de forma integrada o impacto das características de sensores MEMS de baixo custo no desempenho de modelos de aprendizado profundo [Gawde et al. 2023]. Em particular, observa-se uma carência de análises comparativas que considerem simultaneamente a qualidade do sinal adquirido, as condições operacionais em baixas rotações e o desempenho de modelos baseados em Redes Neurais Convolucionais.

2. Metodologia

Esta seção descreve os procedimentos adotados para aquisição, processamento e análise dos sinais de vibração, bem como o desenvolvimento do modelo baseado em Redes Neurais Convolucionais (CNN) para classificação automática de falhas em rolamentos.

2.1. Bancada experimental

Os experimentos foram conduzidos em uma bancada de testes desenvolvida para reproduzir condições reais de operação de máquinas rotativas em regime de baixa rotação. O sistema foi operado a uma velocidade constante de 200 RPM, condição escolhida por representar um cenário crítico para o diagnóstico de falhas, uma vez que sinais vibracionais em baixas rotações apresentam menor amplitude e maior suscetibilidade a ruídos.

A Figura 1, apresenta a bancada experimental composta por um motoredutor Nord DriveSystem, responsável pela geração e transmissão de movimento rotacional, um mancal contendo o rolamento sob análise, um sistema de isolamento vibracional do tipo isomortecedor GERB e um inversor de frequência com Interface Homem-Máquina (IHM), utilizado para controle preciso da velocidade na faixa de 0 a 250 RPM.




Figura 1. Bancada experimental utilizada para aquisição dos sinais de vibração.

As aquisições foram realizadas sob três condições distintas do rolamento: condição normal, defeito na pista interna e defeito no elemento rolante, conforme Figura 2 permitindo a construção de um conjunto de dados rotulado para tarefas de classificação supervisionada.



Figura 2. Características físicas dos rolamentos.

O sensor foi acoplado ao mancal com o objetivo de maximizar a sensibilidade à assinatura vibracional do rolamento e minimizar perdas associadas à propagação estrutural.

2.2. Aquisição e organização dos dados

Os sinais de vibração foram adquiridos por meio de um acelerômetro MEMS de baixo custo (MMA7361), escolhido devido à sua facilidade de integração, baixo consumo de energia e sensibilidade adequada para aplicações em baixas frequências. A Figura 3 apresenta a placa de aquisição com o microcontrolador ESP32 e o sensor MMA7361.



Figura 3. Circuito para aquisição dos Dados.

Os dados foram coletados no domínio do tempo e armazenados em arquivos no formato CSV, contendo amostras discretas de aceleração ao longo do tempo. Posteriormente, o pré-processamento, a organização e a análise dos dados foram realizados no ambiente do Google Colaboratory, utilizando a linguagem Python. Para o desenvolvimento dos modelos de aprendizado profundo, especialmente Redes Neurais Convolucionais (CNNs), foram empregadas bibliotecas como TensorFlow, Keras, além de ferramentas auxiliares como NumPy para manipulação de arrays, Pandas para estruturação e tratamento dos dados, e Matplotlib para visualização gráfica dos resultados. A Figura 4 apresenta o diagrama da Arquitetura do sistema de aquisição de dados.




Figura 4. Diagrama da Arquitetura do sistema.

2.3. Pré-processamento e transformação dos sinais

Inicialmente, os sinais foram padronizados em termos de comprimento, garantindo consistência dimensional entre as amostras por meio da função `ajust_len_array`. Em seguida, foi aplicada a normalização Min-Max, conforme a Equação 1, com o objetivo de reduzir variações de escala e melhorar a estabilidade do processo de treinamento.

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

2.3.1. Justificativa para a representação matricial 8×8

A escolha da dimensão 8×8 para as matrizes bidimensionais foi motivada por três fatores principais: (i) compatibilidade com arquiteturas leves de CNN adequadas para implementação em dispositivos embarcados [Tan and Wannaboorn 2026], (ii) redução controlada da dimensionalidade dos dados mantendo informação temporal relevante, e (iii) equilíbrio entre custo computacional e capacidade de representação de padrões vibracionais.

Representações com dimensões menores (4×4) resultaram em perda excessiva de informação temporal, enquanto dimensões maiores (16×16) não apresentaram ganhos sig-

nificativos de desempenho, aumentando desnecessariamente o custo computacional. A dimensão 8×8 mostrou-se adequada para capturar padrões discriminantes nos sinais de baixa rotação, como evidenciado pela acurácia obtida.

Posteriormente, os sinais foram segmentados utilizando uma abordagem de janela deslizante, permitindo aumentar o número de amostras disponíveis e capturar padrões locais ao longo do tempo. Cada segmento foi então reorganizado em uma matriz bidimensional de dimensão 8×8, possibilitando a utilização de redes convolucionais 2D para extração de características.




Figura 5. Matrizes bidimensionais de dimensões 8x8

2.4. Extração de características e representação dos dados

Embora o modelo proposto utilize aprendizado profundo para extração automática de características, foram também consideradas métricas estatísticas no domínio do tempo com o objetivo de fornecer uma análise complementar do comportamento dos sinais. Entre as métricas utilizadas destacam-se média, desvio padrão, coeficiente de variação, assimetria, curtose, intervalo interquartil e entropia, as quais permitem caracterizar propriedades como dispersão, assimetria e complexidade do sinal. Além disso, o número de amostras por rotação foi estimado com base na velocidade de operação do sistema, conforme as Equações 2–4, garantindo que cada janela de dados represente adequadamente o comportamento dinâmico do rolamento.

$$f_{rot} = \frac{rpm}{60} \quad (2)$$

$$T_{rot} = \frac{1}{f_{rot}} \quad (3)$$

$$n_{samples} = taxa_de_coleta \cdot T_{rot} \quad (4)$$

Após essas etapas, os dados foram organizados no formato tridimensional (8×8×1), incluindo a dimensão de canal necessária para entrada em redes convolucionais, e as classes foram codificadas utilizando o esquema One-Hot Encoding.

2.5. Configuração do modelo e treinamento

A arquitetura da rede neural convolucional foi definida de forma a equilibrar capacidade de representação e custo computacional. O modelo é composto por duas camadas convolucionais com filtros de tamanho 3×3 e funções de ativação ReLU, seguidas por camadas de MaxPooling para redução dimensional. Em seguida, uma camada de achataamento (Flatten) conecta a rede a uma camada totalmente conectada com 64 neurônios,

responsável pela integração das características extraídas. A camada de saída utiliza a função Softmax para classificação multiclasse. O treinamento foi realizado utilizando o otimizador Adam, com taxa de aprendizado de 0,0001, durante 50 épocas e com tamanho de lote de 32 amostras. A função de perda adotada foi a entropia cruzada categórica (*categorical cross-entropy*).

2.6. Avaliação do modelo

A avaliação do modelo foi conduzida por meio de um conjunto de teste independente, correspondente a 10% dos dados, enquanto os conjuntos de treinamento e validação corresponderam a 70% e 20%, respectivamente. O desempenho foi analisado utilizando métricas de acurácia, precisão e recall, além da matriz de confusão, permitindo uma avaliação detalhada da capacidade de classificação do modelo em cada uma das condições do rolamento.

3. Resultados

Esta seção apresenta os resultados obtidos a partir do modelo proposto para classificação de falhas em rolamentos utilizando sinais de vibração adquiridos por acelerômetro MEMS.

3.1. Análise dos dados e pré-processamento

Antes do pré-processamento, os sinais apresentavam comprimentos distintos, conforme observado: 31.914 amostras para condição normal, 31.598 para defeito no elemento rolante e 31.724 para defeito na pista interna. Após a etapa de ajuste de comprimento, todos os sinais foram padronizados para 31.598 amostras, garantindo consistência dimensional entre as classes e permitindo sua utilização em modelos de aprendizado de máquina.

Adicionalmente, foi realizada uma análise espectral dos sinais por meio da Transformada Rápida de Fourier (FFT), com aplicação da janela de Hann para reduzir o vazamento espectral. Os espectros permitiram comparar a distribuição de energia em frequência entre as diferentes condições dos rolamentos, evidenciando diferenças nas componentes espectrais dos sinais e fornecendo indícios de assinaturas vibracionais associadas às distintas condições de operação.

3.2. Geração do conjunto de dados para a CNN

Após a etapa de geração das matrizes 8×8 , obteve-se um total de 23.652 amostras, cada uma representada no formato $(8 \times 8 \times 1)$, o que as torna diretamente compatíveis com a estrutura de entrada de redes neurais convolucionais.

Os dados foram então divididos em três subconjuntos: treinamento (16.556 amostras), validação (4.731 amostras) e teste (2.365 amostras), mantendo proporções de aproximadamente 70%, 20% e 10%, respectivamente.

A distribuição das classes mostrou-se equilibrada entre os subconjuntos, contribuindo para um treinamento mais robusto e reduzindo vieses no modelo.

3.3. Desempenho do modelo

Ao final do treinamento, o modelo apresentou desempenho elevado na tarefa de classificação. No conjunto de teste, foram obtidos os seguintes resultados: acurácia de

94,76%, precisão de 94,76% e recall de 94,76%. Esses valores indicam que o modelo foi capaz de aprender padrões discriminantes nos sinais de vibração, mesmo utilizando dados provenientes de um sensor MEMS de baixo custo.

3.4. Análise da matriz de confusão e Gráfico de Aprendizado

A matriz de confusão, apresentada na Figura 6, evidencia a capacidade do modelo em distinguir corretamente entre as três condições do rolamento. Observa-se um alto número de classificações corretas em todas as classes, com baixa ocorrência de erros de classificação, confirmando a elevada correspondência entre os resultados previstos e os valores esperados.




Figura 6. Matriz de confusão do modelo proposto.

A Figura 7 apresenta as curvas de aprendizado obtidas durante o treinamento, ilustrando a evolução das métricas de acurácia e perda ao longo das épocas. A análise dessas curvas demonstra a convergência adequada do modelo, sem indícios significativos de *overfitting*, o que corrobora sua capacidade de generalização.




Figura 7. Curvas de aprendizado: acurácia e perda durante o treinamento.

3.5. Discussão dos resultados

Os resultados obtidos demonstram que a abordagem proposta é eficaz para a detecção de falhas em rolamentos utilizando sensores MEMS de baixo custo. Mesmo diante das limitações inerentes a esse tipo de sensor, como maior nível de ruído e menor faixa dinâmica, o modelo baseado em CNN foi capaz de extrair características relevantes dos sinais de vibração.

Além disso, a conversão dos sinais para representações bidimensionais mostrou-se uma estratégia eficiente para explorar a capacidade das redes convolucionais na identificação de padrões espaciais, contribuindo diretamente para o desempenho do modelo.

Por fim, os resultados indicam que sensores de baixo custo, quando combinados com técnicas adequadas de processamento de sinais e aprendizado profundo, podem representar uma alternativa viável para aplicações de manutenção preditiva em ambientes industriais.

4. Conclusão

Os resultados obtidos demonstraram que, mesmo diante das limitações inerentes aos sensores MEMS, como maior suscetibilidade a ruídos e menor faixa dinâmica, o modelo proposto foi capaz de alcançar elevado desempenho, com acurácia, precisão e recall superiores a 94%. Além disso, a análise das curvas de aprendizado evidenciou boa capacidade de generalização, sem indícios significativos de *overfitting*, reforçando a robustez da abordagem adotada.

A transformação dos sinais de vibração em representações bidimensionais mostrou-se particularmente eficaz, permitindo explorar de forma adequada as capacidades das CNNs na extração automática de características relevantes. Esse fator foi determinante para o sucesso do modelo, reduzindo a dependência de técnicas tradicionais de engenharia de atributos.

Dessa forma, os resultados indicam que sensores MEMS de baixo custo, quando associados a técnicas adequadas de processamento de sinais e aprendizado profundo, constituem uma alternativa viável para aplicações de manutenção preditiva, especialmente em cenários que demandam soluções escaláveis e economicamente acessíveis.

Como trabalhos futuros, sugere-se a avaliação da abordagem em diferentes condições operacionais, incluindo variações de carga e velocidade, aspectos que alteram significativamente as assinaturas vibracionais dos rolamentos. A influência dessas variáveis operacionais será investigada por meio de protocolos experimentais que contemplem diferentes regimes de operação, permitindo avaliar a robustez do modelo proposto em cenários mais próximos à realidade industrial.

Adicionalmente, pretende-se expandir o conjunto de classes para incluir falhas na pista externa e defeitos combinados, aumentando a abrangência do sistema de diagnóstico. A comparação sistemática com sensores industriais de referência também será conduzida para quantificar precisamente as limitações e vantagens dos sensores MEMS em diferentes condições de operação.

Por fim, a implementação do modelo em dispositivos embarcados, no contexto de *edge computing* ou TinyML, representa um caminho promissor para a realização de

diagnósticos em tempo real em ambientes industriais, reduzindo latência e dependência de infraestrutura centralizada.

Agradecimentos

Os autores agradecem ao Laboratório Oficinas 4.0 do Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP), Campus Guarulhos, pelo suporte técnico e pela infraestrutura disponibilizados ao longo do desenvolvimento deste trabalho. Além disso, agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo fomento por meio da bolsa de Iniciação Científica PIBITI.

Referências

- Abadade, Y., Temouden, A., Bamoumen, H., Benamar, N., Chtouki, Y., and Senhaji Hafid, A. (2023). A comprehensive survey on tinyml. *IEEE Access*.
- Gawde, S., Patil, S., Kumar, S., and Kotecha, K. (2023). A scoping review on multi-fault diagnosis of industrial rotating machines using multi-sensor data fusion. *Artificial Intelligence Review*, 56:4711–4764.
- Hakim, M., Omran, A. A. B., Ahmed, A. N., Al-Waily, M., and Abdellatif, A. (2023). A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: Taxonomy, overview, application, open challenges, weaknesses and recommendations. *Ain Shams Engineering Journal*, 14:101945.
- Lu, C., Wang, Z., and Zhou, B. (2017). Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification. *Advanced Engineering Informatics*, 32:139–151.
- Ompusunggu, A. P., Eryilmaz, K., and Janssen, K. (2021). Condition monitoring of critical industrial assets using high performing low-cost mems accelerometers. In *Procedia CIRP*, volume 104, pages 1389–1394.
- Romanssini, M., Aguirre, P. C. C. d., Compassi-Severo, L., and Girardi, A. G. (2023). A review on vibration monitoring techniques for predictive maintenance of rotating machinery. *Sensors*.
- Sharma, G., Kaur, T., Mangal, S. K., and Kohli, A. (2024). Investigating bearing and gear vibrations with a micro-electro-mechanical systems (mems) and machine learning approach. *Results in Engineering*.
- Sinkittiyant, S. and Ratanasumawong, C. (2024). Fault diagnosis of rolling element bearing from vibration signal using one dimensional convolutional neural networks. In *2024 21st International Joint Conference on Computer Science and Software Engineering (JCSSE)*, pages 390–397.
- Tan, A. and Wannaboon, C. (2026). Lightweight cnn-based bearing fault diagnosis on resource-constrained devices. *International Journal of Innovative Computing, Information and Control*, 22(2):565–578.
- Zhang, S., Zhang, S., Wang, B., and Habetler, T. G. (2020). Deep learning algorithms for bearing fault diagnostics—a comprehensive review. *IEEE Access*.

- Zhao, J., Wang, W., Huang, J., and Ma, X. (2025). A comprehensive review of deep learning-based fault diagnosis approaches for rolling bearings: Advancements and challenges. *AIP Advances*, 15(2):020702.
- Zhu, Z., Lei, Y., Qi, G., Chai, Y., Mazur, N., An, Y., and Huang, X. (2023). A review of the application of deep learning in intelligent fault diagnosis of rotating machinery. *Measurement*, 206:112346.