

XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

Câmpus Itapetininga

DETECÇÃO DE FALHAS EM ROLAMENTOS UTILIZANDO ACELERÔMETROS MEMS DE BAIXO CUSTO E TÉCNICAS DE APRENDIZADO DE MÁQUINA

Carolina Yumi Siroma – FAPESP/IFSP¹
Mestrando João Vitor Pelegrino - IFSP²
Prof. Dr. Wilson Carlos da Silva Júnior - IFSP³
Prof. Rogério Daniel Dantas - IFSP⁴

Introdução

Na indústria moderna, as máquinas rotativas representam a maior parte dos maquinários, sendo componentes essenciais em diversas áreas, como geração de energia, fabricação de equipamentos, transporte e aeroespacial (Peng et al. 2022). Entre as principais peças de máquinas rotativas, destacam-se os mancais de rolamento, responsáveis por suportar cargas axiais e radiais, além de reduzir o atrito rotacional com o eixo (Wang et al., 2019). Sob condições operacionais adversas, como grandes cargas, impactos severos, altas pressões de trabalho e sistemas complexos, os mancais de rolamento estão sujeitos a falhas frequentes em sua pista interna, pista externa e elemento rolante (Zhang, Zhao e Lin, 2021). Esses defeitos são responsáveis por aproximadamente 45% das falhas em maquinários (Nandi, Toliyat e Li, 2005), resultando em paradas não planejadas dos equipamentos e, potencialmente, afetando as linhas de produção, gerando custos significativos e perdas de produtividade. Tradicionalmente, adota-se na indústria a manutenção preventiva, uma das técnicas mais recentes e populares, baseada em substituições planejadas e periódicas de peças das máquinas. No entanto, essa abordagem é ineficiente e custosa, uma vez que, os componentes são substituídos, mesmo que ainda não apresentem defeitos (Kim, An e Choi, 2017). Como alternativa, esse estudo explora a manutenção preditiva, utilizando sensores MEMs (Micro-Electro-Mechanical Systems) para detectar indícios de falhas em sinais de vibração. A expansão da Indústria 4.0 e da tecnologia impulsionam a redução dos custos de produção de sensores, com versões menores e capacidade maior de precisão. Esse cenário viabiliza o monitoramento contínuo de equipamentos, permitindo que operem de forma mais eficiente e prolongada. No cenário atual da tecnologia, torna-se possível a coleta de grandes volumes de dados; porém a

¹Estudante do curso de Bacharelado em Engenharia da Computação, IFSP – Guarulhos/SP. E-mail do primeiro autor: carolina.siroma@aluno.ifsp.edu.br. Orcid: <https://orcid.org/0009-0002-6924-8939>. Lattes: <http://lattes.cnpq.br/6246169968656383>.

²Mestrando em Engenharia Mecânica, IFSP – São Paulo/SP. E-mail autor: v.pelegrino@aluno.ifsp.edu.br. Orcid: <https://orcid.org/0009-0002-5362-9753>.

³Doutor. Instituição onde atua, IFSP – Guarulhos/SP. E-mail do autor: wilsoncarlos@ifsp.edu.br. Orcid: <https://orcid.org/0000-0001-8128-281X>. Lattes: <http://lattes.cnpq.br/3773086146144648>.

⁴Mestre. Instituição onde atua, IFSP – Guarulhos/SP. E-mail do autor: rogerio.dantas@ifsp.edu.br. Orcid: <https://orcid.org/0009-0000-0429-223X>. Lattes: <http://lattes.cnpq.br/6071088942881819>.

XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

Campus Itapetininga

complexidade de processar esses grandes volumes de dados heterogêneos dificulta a identificação manual de padrões relevantes, indicativos de falhas iminentes. Neste contexto, tecnologias baseadas em inteligência artificial surgem como solução promissora, com algoritmos de machine learning capazes de extrair o conhecimento necessário dos dados (Mohri, Rostamizadeh e Talwalkar, 2018).

Objetivo

Este estudo tem como objetivo comparar o desempenho de dois sensores MEMS na aquisição de sinais vibratórios para detecção de falhas em rolamentos, utilizando modelos de machine learning aplicados à manutenção prescritiva. A pesquisa busca avaliar a viabilidade técnica e econômica desses sensores como alternativa aos métodos convencionais no monitoramento de condições de máquinas rotativas, além de identificar qual configuração de algoritmo de aprendizado apresenta melhor desempenho quando integrada a esses sensores. Para isso, uma bancada experimental foi desenvolvida com um motoredutor controlado por um inversor de frequência e conectado a dois mancais de rolamento, incluindo os devidos isolamentos para evitar a interferência de ruídos e vibrações externas. Serão implementados três modelos de inteligência artificial para classificar três condições operacionais distintas: funcionamento normal, defeito na pista externa e defeito nos elementos rolantes. A comparação de diferentes arquiteturas de algoritmos permitirá determinar a configuração mais eficiente para essa aplicação específica. Os resultados deste trabalho podem oferecer uma solução mais acessível para o monitoramento contínuo de máquinas, reduzindo custos operacionais associados aos danos causados por paradas não planejadas. Ao integrar sensores MEMS de baixo custo com técnicas avançadas de machine learning, esta pesquisa contribui para o desenvolvimento de sistemas preditivos mais eficientes.

Metodologia

Para as análises de vibração, foi utilizada uma bancada experimental, disponível no Instituto Federal de São Paulo, Campus Guarulhos. O sistema é composto por um motoredutor conectado a dois mancais de rolamento por meio de um acoplador elástico e um eixo bipartido, montado sobre uma base equipada com isoladores de vibração. O controle de velocidade do sistema é realizado por um inversor de frequência, permitindo a realização de experimentos em diferentes rotações (45, 60, 75 e 90 Hz). Para este trabalho, foram realizados ensaios com dois tipos de defeitos inseridos de forma manual nos rolamentos, sendo eles: defeito no rolo (R) e defeito na pista externa (PE), além da condição normal dos rolamentos (N). A aquisição de dados foi realizada com dois acelerômetros MEMS digitais, os modelos ADXL345 e MPU6050, conectados a um microcontrolador ESP32. A programação foi feita em linguagem C/C++ utilizando a IDE Arduino com adição do plugin ArduSpreadsheet para realizar o armazenamento dos dados, enviados via comunicação serial, em formato CSV. No processamento de sinais vibratórios para detecção de falhas em rolamentos, trabalhar com os dados em sua forma bruta frequentemente não resulta nos melhores resultados, portanto, para extrair a identidade de cada tipo de vibração referente aos defeitos, os sinais de saída adquiridos foram submetidos à um processamento matemático, a Transformada Rápida de Fourier (FFT). Na etapa de classificação, foram utilizados diferentes métodos de aprendizado de máquina; o KNN (K-

XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

Campus Itapetininga

Nearest Neighbors) realiza a comparação entre instâncias com base no cálculo da distância entre dados no espaço euclidiano; a Árvore de Decisão é um método de aprendizado supervisionado não paramétrico que constrói modelos baseados em regras simples extraídas das características dos dados. A abordagem mais sofisticada envolveu o uso de Redes Neurais Convolucionais 1D (CNN 1D), onde kernels deslizantes aplicam operações de convolução sobre os sinais temporais, extraindo características relevantes através de pesos ajustáveis. A combinação desses métodos permitiu uma análise comparativa da capacidade de classificação dos modelos aplicados, para diferentes condições de falhas em rolamentos.

Resultados

A base de dados foi dividida em 70% para treinamento dos modelos e 30% para testes, na KNN e Árvore de Decisão, enquanto para a CNN 1D foi utilizada uma divisão de 70% treinamento, 15% teste e 15% validação. Realizou-se, também, a padronização dos dados (Standard Scaler), além da aplicação de um Autoencoder, uma arquitetura de rede neural que compacta os dados de entrada, extraindo as características principais e posteriormente reconstruindo a informação original. Para a frequência de 75Hz no sensor ADXL345: no modelo KNN, sem aplicação da FFT, obteve-se uma precisão de 93,41%, com a utilização da FFT, a precisão aumentou para 99,86%; para a Árvore de Decisão, observou-se uma acurácia de 87,40% sem a aplicação da FFT e de 96,99% com a FFT; a CNN 1D dispensou o uso da FFT, devido à capacidade da rede de extrair características relevantes dos sinais temporais de vibração, com 2.499 parâmetros treináveis, alcançou uma perda de apenas 0,00165 e uma acurácia de 99,95% no conjunto de teste. Para o sensor MPU6050 a 75Hz: a rede KNN com FFT obteve 98,93% de acurácia, a Árvore de Decisão alcançou 92,27%, a CNN 1D teve perda de 0,04025 e acurácia de 99,04%. Para o sensor ADXL345 a 90Hz: a rede KNN obteve 100% de acurácia, a Árvore de Decisão alcançou 99,79%, a CNN 1D teve perda de 0,00079 e a acurácia de 99,95%. Para o sensor MPU6050 a 90Hz: a rede KNN obteve 98,54% de acurácia, a Árvore de Decisão alcançou 88,94%, a CNN 1D teve perda de 0,04685 e a acurácia de 98,95%.

Conclusão

O modelo de Rede Neural Convolucional 1D (CNN 1D) demonstrou eficácia na detecção de padrões nos dados vibratórios e destacou-se por dispensar a necessidade de pré-processamento e transformações adicionais nos dados de entrada. Os experimentos realizados mostraram que a aplicação da Transformada Rápida de Fourier (FFT) melhora significativamente o desempenho dos modelos, como observado nas redes KNN e Árvore de Decisão. Nota-se ainda que o sensor ADXL345 apresentou um desempenho levemente superior ao MPU6050, alcançando melhores resultados de acurácia, especialmente em frequências mais altas (90Hz). A pesquisa aponta, dessa forma, a importância do desenvolvimento de sistemas de manutenção preventiva. A combinação de técnicas de aprendizado de máquina, especialmente as redes convolucionais, e sensores de baixo custo apresentam-se como uma promissora abordagem para a detecção precoce de falhas rolamentos. Destaca-se, também, a importância da análise e comparação das diversas possibilidades e combinações, que permitem alcançar melhores resultados.

XI CONGRESSO DE INICIAÇÃO CIENTÍFICA DO IFSP ITAPETININGA

Itapetininga, 27, 28 e 29 de maio de 2025

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

Campus Itapetininga

Referências

PENG, B.; BI, Y.; XUE, B.; ZHANG, M.; WAN, S. A survey on fault diagnosis of rolling bearings. *Algorithms*, Basel, v. 15, n. 10, art. 347, 2022. DOI: <https://doi.org/10.3390/a15100347>.

WANG, Jianyu; MO, Zhenling; ZHANG, Heng; MIAO, Qiang. A deep learning method for bearing fault diagnosis based on time-frequency image. *IEEE Access*, Piscataway, NJ, v. 7, p. 42373–42383, 2019.

ZHANG, X.; ZHAO, B.; LIN, Y. Machine learning based bearing fault diagnosis using the Case Western Reserve University data: a review. *IEEE Access*, Piscataway, NJ, v. 9, p. 155598–155608, 2021. DOI: 10.1109/ACCESS.2021.3128669.

NANDI, S.; TOLIYAT, H. A.; LI, X. Condition monitoring and fault diagnosis of electrical motors—a review. *IEEE Transactions on Energy Conversion*, Piscataway, NJ, v. 20, n. 4, p. 719–729, Dec. 2005. DOI: 10.1109/TEC.2005.847955.

KIM, Nam-Ho; AN, Dawn; CHOI, Joo-Ho. *Prognostics and health management of engineering systems: an introduction*. Cham: Springer, 2017. DOI: <https://doi.org/10.1007/978-3-319-44742-1>.

MOHRI, Mehryar; ROSTAMIZADEH, Afshin; TALWALKAR, Ameet. *Foundations of machine learning*. Cambridge, MA: MIT Press, 2018.