cbecimat26
26° Congresso Brasileiro de Engenharia e Ciência dos Materiais
22 a 26 de novembro de 2026
Costão do Santinho
Florianópolis-SC

Avaliação Comparativa de Arquiteturas de Deep Learning para a Manutenção Preventiva e Prescritiva de Rolamentos Autocompensadores de Rolos

Lucas Pataro Fernandes[1]; Lucas Almeida Willenshofer[2]; Rogério Daniel Dantas[3]; Vanessa Seriacopi[4]; Flavia Gonçalves Lobo[5]; Wilson Carlos da Silva Junior[6].
1.Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

Introdução

A transição para a manutenção prescritiva exige métodos autônomos de diagnóstico. O monitoramento de rolamentos autocompensadores (350 RPM) impõe um desafio, pois os microimpactos gerados por falhas incipientes possuem baixa energia e são ofuscados pelo ruído. Este trabalho soluciona isso aplicando Inteligência Artificial sobre dados de um acelerômetro MEMS de baixo custo.

Objetivos

Avaliar a eficácia de três arquiteturas de Deep Learning (CNN Base, MSCNN e CNN-LSTM com Autoatenção) na classificação de avarias em rolamentos autocompensadores de rolos operando em baixíssima rotação.

Metodologia

Os ensaios utilizaram rolamentos autocompensadores de rolos, divididos em três categorias de integridade estrutural: (a) condição íntegra; (b) defeito induzido na pista externa por retífica; e (c) defeito induzido nos elementos rolantes.

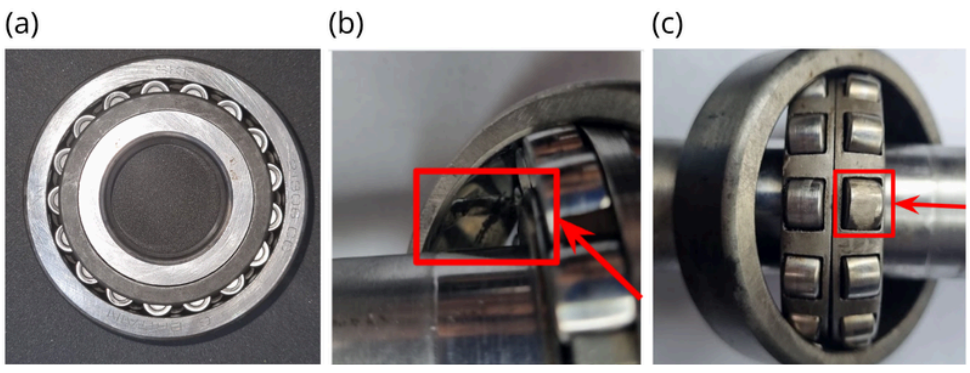

Figura 1. Corpos de prova dos rolamentos autocompensadores de rolos.

Os sinais vibratórios foram capturados por um acelerômetro triaxial (MEMS ADXL345). Para a extração de características pela IA, as séries temporais (1D) sofreram uma conversão topológica espacial: os eixos X, Y e Z foram mapeados respectivamente para os canais de cor RGB, gerando tensores tridimensionais com resolução de 28x28x3.

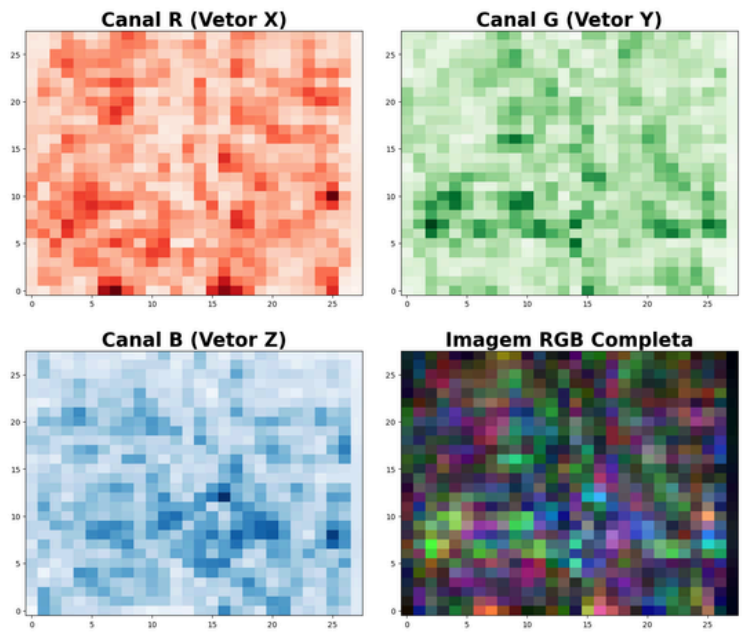

Figura 2. Visualização de sinal triaxiais (X, Y, Z) via mapeamento espectrográfico RGB.

Resultados e Discussão

A avaliação comparativa, detalhada nas matrizes de confusão e na tabela de desempenho a seguir, comprova a superioridade absoluta da arquitetura híbrida (CNN-LSTM com Autoatenção), que atingiu acurácia de 99,88% e taxa de perda de 0,0041. A sinergia entre o processamento espacial e a retenção temporal (LSTM) induziu a atenção dinâmica aos instantes exatos de impacto.

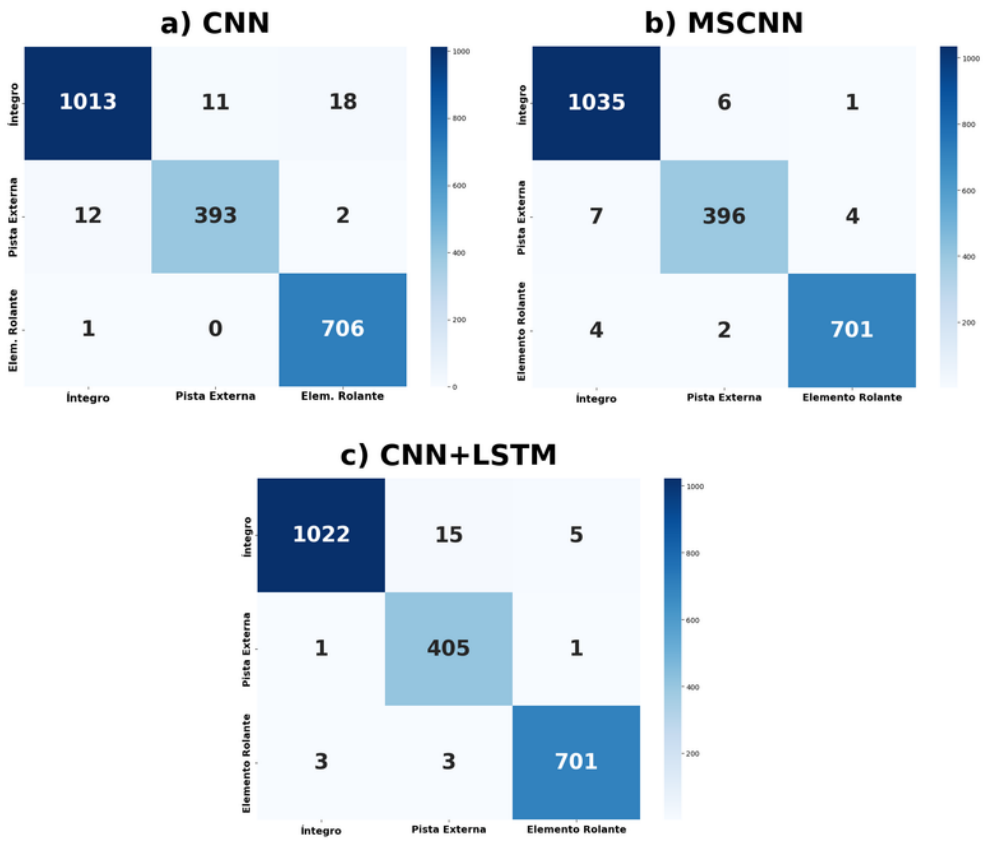

Figura 3. Matrizes de confusão para os modelos aplicados ao diagnóstico de falhas em rolamentos com base nos espectrogramas RGB

Arquitetura	Acurácia (%)	Loss
CNN Base	97,85	0,0842
MSCNN	99,12	0,0315
CNN-LSTM + Atenção	99,88	0,0041

Tabela 1 - Comparação das métricas de desempenho das arquiteturas avaliadas.

Conclusões

O estudo comprova a viabilidade técnica do diagnóstico de falhas em maquinários sob regime de baixa rotação, utilizando sensoriamento MEMS. A sinergia entre a conversão topológica de dados vibratórios (1D para 3D) e o uso de redes neurais atencionais consolida uma abordagem altamente imune a ruídos mecânicos de fundo. Essa arquitetura estabelece uma base algorítmica para viabilizar a manutenção prescritiva e o embarque em sistemas de borda (Edge Computing) em Internet das Coisas (IoT).

Agradecimentos

Agradecemos à Termomecânica São Paulo S.A. e à NORD DRIVESYSTEMS Brasil Ltda. pelo apoio e pela colaboração no desenvolvimento deste projeto.

Referências

AREZ, A.; NAVAS, S.; GASPAR, P. The bridge between artificial intelligence and predictive maintenance in Industry 4.0: A systematic review. Applied Sciences, v. 16, n. 10, p. 4882, 2026.
WANG, L.; ZHAO, W. An ensemble deep learning network based on 2D convolutional neural network and 1D LSTM with self-attention for bearing fault diagnosis. Applied Soft Computing, 2025.
ANWARSHA, A.; T, N. B. Fault detection of taper roller bearings using tunable q-factor wavelet transform and fault classification using long-short-term memory network. Scientific Reports, 2025.