

Aprendizado profundo na indústria: desenvolvimento de uma rede neural profunda para manutenção preditiva em máquinas rotativas industriais

Marcones Cleber Brito da Silva, pro21001731@cefsa.edu.br, Faculdade Engenheiro Salvador Arena

Gustavo Pelegrino, 061230022@faculdade.cefsa.edu.br, Faculdade Engenheiro Salvador Arena

Matheus Galdino Xavier, 082210042@faculdade.cefsa.edu.br, Faculdade Engenheiro Salvador Arena

Resumo

A manutenção preditiva tem se consolidado como uma estratégia eficaz na indústria para prevenir falhas e otimizar o desempenho de máquinas rotativas. Dentre os parâmetros analisados, a vibração mecânica se destaca por refletir diretamente o estado operacional do equipamento. Tradicionalmente, a Transformada Rápida de Fourier (FFT) tem sido empregada na análise desses sinais, exigindo conhecimento técnico especializado e ferramentas específicas. Este trabalho propõe o desenvolvimento de modelo de rede neural profunda como alternativa para a detecção automática de anomalias em sinais de vibração, com foco na simplificação do processo de diagnóstico. A pesquisa será conduzida a partir de uma bancada experimental já existente, a qual simula desalinhamentos em eixos rotativos por meio de sensores de vibração integrados a um sistema de aquisição de dados em LabVIEW. O objetivo principal é implementar uma solução baseada em aprendizado profundo que seja capaz de identificar padrões anômalos e inferir relações de dependência entre variáveis do processo, dispensando o uso direto da FFT na análise final. A validação da abordagem será realizada por meio da comparação dos resultados obtidos com dados de referência na literatura, evidenciando a capacidade da rede neural em interpretar o comportamento dinâmico da máquina e auxiliar em ações preditivas de manutenção.

Palavras-chave: Manutenção preditiva. Aprendizado profundo. Vibração. Bancada experimental. Detecção de falhas.

Introdução

Segundo Silva (2023) e Ferro (2021), dois dos principais fatores que geram vibrações mecânicas em máquinas rotativas são o desbalanceamento e o desalinhamento. O desbalanceamento ocorre devido à distribuição desigual de massa em componentes rotativos, o que gera forças centrífugas periódicas, principalmente na direção radial, com frequência dominante igual à velocidade de rotação (1x RPM – “1 vez a rotação por minuto”). A intensidade das vibrações aumenta proporcionalmente ao quadrado da rotação. A depender do tipo, como desbalanceamento de força, acoplamento ou conjugado. E podem surgir variações significativas na fase em relação ao e a amplitude através de uma vibração senoidais característicos da frequência de rotação na direção radial, ou com grande amplitude na direção axial, como mostrado no espectro típico da Figura 1.

Figura 1 – Comportamentos dos tipos de desbalanceamento

Espectro típico	Relação de fases	Observações
1X RADIAL	Desb. Estático	O desbalanceamento de forças está em fase e permanece. A amplitude do desbalanceamento aumenta com o quadrado da velocidade. O pico aparece na frequência de 1x RPS e sempre está presente dominando o espectro de sinal. Pode ser corrigida pela colocação de um peso de balanceamento em um plano no centro de gravidade do Rotor (CG).
1X RADIAL	Desbalanceamento Conjugado	O Desbalanceamento de Acoplamento tende a ficar 180° fora de fase no mesmo eixo. A amplitude se apresenta na frequência de 1X RPS e domina o espectro de sinais. A amplitude varia com o quadrado do crescimento da velocidade. Pode provocar vibrações axiais e radiais elevadas. A correção exige a colocação de pesos de balanceamento em pelo menos 2 planos. Pode existir aproximadamente 180° de diferença entre a fase de movimento nas horizontais OB e IB, bem como entre as verticais OB e IB.
1X AXIAL & RADIAL	Desb. Axial	O Desbalanceamento do Rotor em Balanço causa elevada amplitude em 1X RPS tanto na direção axial como na direção radial. Leituras axiais tendem a estar em fase, enquanto leituras de fase radiais podem ser instáveis. Rotores em balanço comumente têm desbalanceamento de força e de acoplamento, cada um dos quais exigirá igualmente que se faça a correção.

Fonte: Sá Mauro (2003).

Para os autores, as vibrações axiais e radiais elevadas são sintomas comuns, com picos ocorrendo em múltiplas ordens da frequência de rotação (1x, 2x, 3x RPM ou até mesmo harmônicos superiores), como ilustrado na Tabela da Figura 2. Essa condição intensifica o desgaste de rolamentos, aumenta o consumo energético e reduz a vida útil do equipamento. Ao diagnosticar esses fenômenos, destaca a importância da análise de parâmetros como frequência, amplitude, forma de onda, espectro de frequência, aceleração, velocidade e deslocamento. Esses dados são essenciais para a caracterização precisa da condição operacional da máquina, permitindo a detecção precoce de falhas e a aplicação eficaz da manutenção preditiva.

Figura 2 – Comportamentos dos tipos de desalinhamentos

Espectro típico	Relação de fases	Observações
AXIAL 1X 2X 3X	Desalinhamento Angular	O Desalinhamento Angular é caracterizado pela alta vibração axial, 180° fora de fase através do acoplamento. Caracteristicamente haverá alta vibração axial tanto com 1x quanto com 2x RPM. Entretanto não é incomum que 1x, 2x ou 3x sejam dominantes. Estes sintomas podem indicar também problemas de acoplamento.
1X 2X RADIAL 3X	Desalinhamento Paralelo	Desalinhamento Paralelo tem sintomas similares ao Angular, mas apresenta vibração radial alta que se aproxima de 180° fora de fase através do acoplamento. 2x é muitas vezes maior que 1x, mas sua altura relativa para 1x é habitualmente ditada pelo tipo e construção do acoplamento. Quando o Desalinhamento Angular ou Radial se torna severo, pode gerar picos de alta amplitude em harmônicos muito mais altos (4x-8x) ou mesmo toda uma série de harmônicos de alta frequência similar na aparência à folga mecânica. A construção do acoplamento influenciará muitas vezes a forma do espectro quando o desalinhamento é severo.

Fonte: Sá Mauro (2003).

Segundo Tama et al. (2023), no contexto da inteligência artificial, os métodos tradicionais de aprendizado de máquina requerem a extração manual de características relevantes dos sinais de vibração para posterior classificação. Em contrapartida, as abordagens baseadas em *Deep Learning* permitem que essas características sejam aprendidas automaticamente a partir dos dados brutos, aumentando tanto a eficiência quanto a precisão no diagnóstico de falhas.

Ainda conforme o autor, entre as arquiteturas mais utilizadas destacam-se as redes neurais convolucionais (CNNs ou *Convolutional Neural Network* – “Rede Neural Convolucional”), que podem ser

aplicadas diretamente em séries temporais ou em representações bidimensionais dos sinais; as redes neurais recorrentes (RNNs ou Recurrent Neural Network – “Rede Neural Recorrente”), apropriadas para modelagem sequencial; suas variantes LSTM (*Long Short-Term Memory* – “Memória de Longo e Curto Prazo”), capazes de captar relações temporais de longo prazo; os *autoencoders*, empregados para aprendizado não supervisionado; e, mais recentemente, as redes neurais baseadas em gráficos (GNNs), que modelam relações estruturais complexas entre dados.

Segundo Cui (2021), a aplicação de técnicas de inteligência artificial na análise de vibração tem transformado o diagnóstico de falhas em máquinas rotativas, tornando a manutenção preditiva mais eficaz e precisa. Entre as técnicas mais exploradas estão as CNNs, amplamente utilizadas em dados com estrutura espacial ou sequencial, como séries temporais ou imagens derivadas desses sinais.

Conforme os autores, as CNNs unidimensionais (1D) operam diretamente sobre sinais de vibração no domínio do tempo, utilizando filtros convolucionais para extrair automaticamente padrões relevantes, sem a necessidade de pré-processamento manual. Esse tipo de abordagem mostra-se eficiente na identificação de falhas, principalmente em fases iniciais. No estudo de Vianna (2024), foi observada uma aplicação híbrida dessa técnica combinada com Máquinas de Vetores de Suporte (SVM), sendo essa combinação a que apresentou os melhores resultados, superando inclusive o desempenho da CNN aplicada isoladamente.

Segundo Tama et al. (2023), a arquitetura LSTM tem se mostrado eficaz na modelagem de dados sequenciais e temporais, permitindo acompanhar a evolução progressiva de falhas ao longo do tempo por meio da detecção de anomalias. Essa capacidade é especialmente relevante em aplicações onde os sinais apresentam padrões temporais sutis ou progressivos.

Para Campos (2023), a aplicação isolada da LSTM na predição de falhas em rolamentos de motores elétricos não apresentou resultados suficientemente robustos. No entanto, ao ser combinada com representações no domínio *wavelet* ou integrada a redes CNN, foi possível alcançar um aumento considerável na confiabilidade dos diagnósticos, evidenciando o potencial das abordagens híbridas.

Metodologia

O kit concebido inicialmente no estágio inaugural deste projeto se caracterizava pelo desenvolvimento de uma aplicação destinada a balanceamento e desbalanceamento de um motor, medindo com o aplicativo de Celular *iDynamics*, com sua frequência ajustada para 500Hz, visando o estudo realizado sobre Nyquist, em relação ao aliasing, e realizando as medições em cada uma das situações descritas, no mancal dianteiro, no mancal traseiro, de modo que o próprio celular ficasse perpendicular com a superfície e ao mesmo tempo, transformando os dados em um formato CSV para exportação deles, se caracterizando os campos (colunas) do banco de dados como: número de amostragem (i, index), tempo em ms, aceleração do eixo X em m/s^2 , aceleração do eixo Y em m/s^2 , aceleração do eixo Z em m/s^2 , cada uma das mensurações foi realizado por no mínimo 4 minutos, sem mexer o dispositivo. Foi desenvolvido um classificador de vibração para detecção de falhas em motores, considerando quatro condições: balanceado, desalinhamento angular, desalinhamento linear e desbalanceado, conforme explicados anteriormente na pesquisa. A metodologia manteve rigor experimental e reprodutibilidade, desde a preparação da base de dados até o modelo final.

Os dados, provenientes de arquivos unificados em dois bancos de dados em formato XLSX, para o mancal dianteiro e traseiro, para após adicionar um campo (coluna) rotulado de “Condicao”, retratando qual a respectiva condição de cada registro, marcando header na linha 0, interpolar valores ausentes, verificar se

há registros duplicados, imprimindo quantos dados tem em cada condição analisada para não ficar enviesado o modelo.

No pré-processamento, foram removidas colunas monotônicas ou de baixa variância, normalizados os valores com *StandardScaler*, devido a escala dos valores, e aplicadas técnicas de média móvel para eliminar deriva lenta. As séries temporais foram segmentadas em janelas de 160 amostras (*stride* 16) e submetidas a z-score local para redução de discrepâncias de ganho.

A divisão dos conjuntos foi realizada por arquivo (*group-aware*), evitando *data leakage* e garantindo que o modelo fosse avaliado apenas em dados inéditos. Inicialmente, utilizou-se uma arquitetura LSTM, que apresentou bom desempenho em divisões aleatórias, mas instabilidade e *overfitting* na avaliação correta.


Diante disso, adotou-se dois modelos de CNN 1D, desenvolvidos no Google Collab, com Python 3, GPUs: T4, 12,7 GB de memória RAM e 15 GB de GPU. Ambos os modelos são de arquitetura CNN, um deles composto por três camadas Conv1D (*kernels* 11, 7 com *dilation*=2 e 3), seguidos de *Batch Normalization* (visando evitar o *overfitting*), pooling, *Global Average Pooling* e uma camada densa com 64 neurônios e *Dropout* de 0,3, finalizando com saída *softmax*. O treinamento foi realizado com Adam, *focal loss* ($\gamma=2$), pesos por classe, *early stopping* (paciência 12) e *ReduceLROnPlateau*. Enquanto o outro modelo foi desenvolvido, com outros parâmetros, reduzindo a complexidade da arquitetura, diminuindo o *batch* para 16, utilizando filtros da camada L1 que adicionam matriz, para evitar o *overfitting*.

A avaliação contemplou acurácia global, métricas por classe (precisão, recall, F1-score), matriz de confusão e histórico de treino. O modelo, métricas e parâmetros foram salvos em formatos adequados (Keras, JSON, CSV e PNG), assegurando reprodutibilidade e rigor científico.

Resultados preliminares

Seguindo o critério e a arquitetura montadas, alterando parâmetros e simplificando a estrutura da CNN anteriormente descrita foram obtidos os seguintes resultados, representado na Figura 3.


Figura 3 – Parâmetros de acurácia e perda do modelo 2 realizado, com arquitetura alterada



Fonte: Autoria própria (2025).

Enquanto a arquitetura descrita com os parâmetros exatamente iguais obteve-se o seguinte resultado representado na Figura 4.

Figura 4 – Parâmetros de acurácia e perda do modelo 2 realizado com a arquitetura exatamente igual a descrita



Fonte: Autoria própria (2025).

Referências

CAMPOS, R. C. **Precisão de falhas em rolamentos de motores elétricos com a utilização de técnicas de Deep Learning**. Serra, 2023. Disponível em: <https://repositorio.ifes.edu.br/bitstream/handle/123456789/3728/DISSERTACAO_Predi%c3%a7%c3%a3o_Falha_Rolamentos_Utilizando_DeepLearning.pdf?sequence=2&isAllowed=y>. Acesso em: 09 de mai. de 2025.

CUI, W.; MENG, G.; WANG, A.; ZHANG, X.; DING, J. **Application of rotating machinery fault diagnosis based on deep learning: shock and vibration**. s.l., 2021. Disponível em: <<https://doi.org/10.1155/2021/3083190>>. Acesso em: 09 de mai. de 2025.

FERRO, E. M.; CURI, E. I. M. **Bancada de ensaio para detecção de falhas de desbalanceamento, desalinhamento e folga mecânica**. Brasil, 2012. Disponível em: <<https://repositorio.satc.edu.br/bitstream/satc/734/2/Eduardo%20Monteiro%20Ferro.pdf>>. Acesso em 23 de jun. de 2025.

SILVA, D. O.; BIAZON, L. G.; SANTOS, T. B.; NOVAES, Y. S.; COSTA, A. F. **Manutenção preditiva: análise de vibrações na indústria 4.0**. Curitiba, 2023.

TAMA, B.A.; VANIA, M.; LEE, S.; LIM, S.; **Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals**. Artif Intell Rev 56, 4667–4709. s.l., 2023. Disponível em: <<https://doi.org/10.1007/s10462-022-10293-3>> Acesso em: 09 de mai. de 2025.

VIANNA, V. S. **Detecção de falhas em mancais de esferas através de modelo de inteligência artificial híbrido CNN-SVM**. Campinas, 2024. Disponível em: <<https://repositorio.unicamp.br/Busca/Download?codigoArquivo=578588&tipoMidia=0>>. Acesso em: 09 de mai. de 2025.