

MANUTENÇÃO PREDITIVA: CLASSIFICAÇÃO AUTOMÁTICA DE FALHAS EM MÁQUINAS ROTATIVAS UTILIZANDO DEEP LEARNING.

Wenisten Dantas¹; Erick Giovani Sperandio Nascimento²

Bolsista; Projeto de implantação de infraestrutura de Pesquisa em Simulação e Modelagem Computacional no estado da Bahia Utilizando Processamento de Alto Desempenho – Fundação de Amparo à Pesquisa do Estado da Bahia – FAPESB; Wenisten.silva@fieb.org.br

²Doutorado; Centro Universitário SENAI CIMATEC; Salvador-BA; erick.sperandio@fbter.org.br

RESUMO

Por conceito, a manutenção preditiva busca a previsão de falhas, no que tange aos equipamentos rotativos suportados por um mancal de rolamentos, o que leva a uma maior confiabilidade operacional e capacidade de planejamento prévio da intervenção ampliando a manutenibilidade do equipamento. A aplicação de modelagem computacional através da aprendizagem profunda (*deep learning*) permite a utilização de técnicas de classificação e regressão para que uma determinada falha seja identificada, classificada e que sua condição futura seja prevista com grau de confiança aceitável sem a intervenção humana, viabilizando um planejamento prévio da intervenção. Este trabalho visa apresentar um esforço na direção de se construir uma metodologia baseada em aprendizagem profunda para a classificação automática de falhas em equipamentos rotativos.

PALAVRAS-CHAVE: REDES NEURAI, PREVISÃO, VIBRAÇÃO, ROLAMENTO.

1. INTRODUÇÃO

A manutenção de equipamentos rotativos e grandes máquinas é fundamentada por normas e padrões já estabelecidos mundialmente. A abrangência internacional destas normas permite que o ciclo de desenvolvimento e fabricação dos equipamentos e sobressalentes suportados por ela, estejam dentro de um padrão único e globalizado. Em 1995 foi lançada a primeira versão da norma ISO 10816-1³ que estabelece os limites de vibração aceitáveis para equipamentos rotativos, assim como a forma correta de medição. Na rotina da monitoração de falhas em mancais de rolamento o acompanhamento do valor eficaz da velocidade ao longo do tempo é comparado aos limites operacionais da norma conforme Tabela-1³ sendo então dado o tratamento conforme criticidade.

Tabela 1 - Zona típica de limites da norma ISO-10816

Norma ISO 10816 - Classe de equipamento				
R.m.s (mm/s)	Classe I	Classe II	Máquinas Grandes	
	Máq. Pequena	Máq. Média	Classe II fundação rígida	Classe IV fundação flexível
0,28	A	A	A	A
0,45				
0,71				
1,12	B	B	B	B
1,8				
2,8	C	C	C	C
4,5				
7,1	D	D	D	D
11,2				
18				
28				
45				

Zona A Verde: valores de vibração operacionais.
Zona B Amarelo: Operação contínua sem restrições
Zona C Laranja: Condição é aceitável apenas por um período limitado de tempo.
Zona D Vermelha: Valores de vibração perigosos – falha iminente.

A identificação e classificação de falhas em equipamentos é um processo geralmente custoso, manual, e que demanda tempo de profissionais treinados e capacitados para esse fim. Em um cenário em que há cada vez mais maquinário industrial sendo utilizado, torna-se premente a necessidade de se buscar alternativas confiáveis e mais automatizadas para a identificação de falhas em equipamentos. Portanto, o objetivo deste trabalho é demonstrar a aplicação de redes neurais na classificação da falha contribuindo com diagnóstico prévio.

2. METODOLOGIA

Para este trabalho foram utilizados dados do repositório MAFAULDA, que é um banco de dados de falha de máquina rotativa (MAFAULDA -Machinery Fault Database²). Os dados são da monitoração de um conjunto

rotativo composto por acionador e acionado, representados aqui por um motor e um disco metálico, classificados em seis condições operacionais distintas com variações no modo de falha totalizando 1952 conjuntos de dados obtidos de 8 sensores com amostragem de 50khz durante 5s, totalizando 250.000 dados por amostra.

Os sensores estão distribuídos conforme ordem: tacômetro; mancal acoplado: vertical, horizontal e axial; mancal oposto: vertical, horizontal e axial; e sinal do áudio proveniente de um microfone. Os dados foram registrados na mesma ordem. Devido a relações mecânicas diretas no acoplamento entre elemento acionador e o acionado, foram selecionados os dados do tacômetro e mancal do lado acoplado formando um conjunto de quatro variáveis arranjadas para treinamento e inferência da rede. Neste estudo, portanto, serão utilizados os três sensores de vibração do mancal acoplado (vertical, horizontal e axial), mais as informações de rotação do tacômetro. Assim, de um total de 8 sensores, utilizaremos dados de somente 4 sensores, representando um leiaute mais comum do monitoramento de máquinas rotativas na indústria.

Os mancais de rolamento apresentam falhas incipientes que não são observáveis no primeiro plano de inspeção através do valor eficaz, sendo possível somente através da transformada rápida de Fourier em conjunto com filtros de frequências e filtragem de ruído. A observação e identificação destas falhas requer elevada expertise do operador.

Com a modelagem de redes neurais para classificação das falhas, é possível identificá-las nos estágios prematuros sem a intervenção humana. Uma das características predominantes em redes neurais é sua capacidade de aprender com base em um número finito de exemplos e de inferir sobre este aprendizado⁵.


A obtenção dos dados que formam o gráfico da transformada rápida de Fourier (FFT) de um sinal, ocorre ao processar todo o sinal do acelerômetro na equação da FFT (1), sendo possível filtrar e catalogar as condições de falha para todas as séries de dados e então submetendo a inferência na rede neural de classificação.

$$X(m) = \frac{1}{N_a} \sum_{n=0}^{N_a-1} x(n)e^{-i2\pi\left(\frac{nm}{N_a}\right)} \quad (1)$$

3. RESULTADOS E DISCUSSÃO

Calculando a FFT do sinal do sensor 1, temos na Figura 1 o espectro da frequência na faixa de 0 a 400hz para a rotação 1400rpm. Comparando o resultado com a Figura 2 do mesmo sensor, é possível verificar a mudança da escala no eixo da amplitude devido ao pico representado pela *amplitude da* frequência 225hz. Esta discrepância ocorre em função da falha instalada na esfera do rolamento, o que permitiu categorizar um padrão para cada condição de falha simulada.

Figura 1 – FFT de um mancal sem falha a 1400rpm. Figura 2 - FFT de um mancal com falha na esfera.



Há casos onde existe similaridade entre as falhas e quando analisadas a partir da observação visual apresentam similaridade essa é uma condição pode levar a um diagnóstico errado. Na classificação das falhas através do método computacional, os valores de cada espectro são analisados e suas nuances são capturadas, permitindo identificar as falhas e a correta distinção delas.

Ao classificar 8 falhas com um total de 30 classes em uma CNN (rede neural convolucional) o resultado da acurácia geral foi de 97,25%. A Tabela 2 mostra a acurácia em relação ao total de amostras de cada classe.

Tabela 2 - Percentual de acerto da classificação considerando somente os 3 sensores referentes à vibração do mancal a interno utilizando redes neurais convolucionais

Classe	Tipo de Falha	% de acerto	Acuracia total
0	Operação sem falha	100,00%	
1	Desalin, horizontal: 0,5mm	99,39%	
2	Desalin, horizontal: 1,0mm	100,00%	
3	Desalin, horizontal: 1,5mm	99,35%	
4	Desalin, horizontal: 2,0mm	100,00%	
5	Desalin, vertical: 0,51mm	90,00%	
6	Desalin, vertical: 0,63mm	96,07%	
7	Desalin, vertical: 1,27mm	96,61%	97,25%
8	Desalin, vertical: 1,40mm	84,00%	
9	Desalin, vertical: 1,78mm	94,48%	
10	Desalin, vertical: 1,90mm	78,72%	
11	Desbalanceado em:6g	99,42%	
12	Desbalanceado em:10g	100,00%	
13	Desbalanceado em:15g	99,40%	
14	Desbalanceado em:20g	100,00%	

Continua

Classe	Tipo de Falha	% de acerto	Acuracia total
15	Desbalanceado em:25g	98,62%	
16	Desbalanceado em:30g	97,60%	
17	Desbalanceado em:35g	97,73%	
18	Falha na esfera	99,44%	
19	Falha na esfera: 6g	100,00%	
20	Falha na esfera: 20g	100,00%	
21	Falha na esfera: 35g	99,21%	
22	Falha na gaiola: 0g	100,00%	97,25%
23	Falha na gaiola: 6g	97,77%	
24	Falha na gaiola: 20g	98,40%	
25	Falha na gaiola: 35g	99,27%	
26	Falha na pista externa: 0g	99,40%	
27	Falha na pista externa: 6g	99,39%	
28	Falha na pista externa: 20g	99,42%	
29	Falha na pista externa: 35g	96,12%	

Fonte: Próprio autor

Os valores apresentados na Tabela 2 são oriundos de dados que não foram apresentados para treinamento ou validação, sendo estes utilizados para teste final do modelo. A acurácia alcançada neste estudo é de grande relevância, tendo alcançado ótimos resultados. Conforme a norma ISO 13373-1, o monitoramento de vibração é conduzido para auxiliar na avaliação da saúde da máquina durante a operação¹. A elaboração do modelo computacional utilizando *Deep Learning* para classificação e identificação de falhas incipientes irá prover um diagnóstico preciso da condição.

4. CONSIDERAÇÕES FINAIS

Este trabalho propõe uma abordagem moderna para identificação de falhas, desde às incipientes até as maiores, em mancais de rolamentos com a identificação destas por meio da aplicação de redes neurais com aprendizado profundo, buscando prover à manutenção uma nova abordagem na previsão da condição de máquina, tornando uma rotina de inspeção avançada que antes era sob demanda com a intervenção humana em rotina diária em modo automático.

Agradecimentos

Este trabalho contou com o apoio da FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia), na forma de uma bolsa de Desenvolvimento de Inovação Tecnológica no projeto "Implantação de Infraestrutura de Pesquisa em Simulação e Modelagem Computacional no Estado da Bahia Utilizando Processamento de Alto Desempenho", desenvolvido no Centro de Supercomputação para Inovação Industrial do SENAI CIMATEC.

5. REFERÊNCIAS

- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO13373-1 - Condition monitoring and diagnostics of machines**: Vibration condition monitoring. San Diego,CA: Machinery Information Management Open Systems Alliance (MIMOSA), 2-3, 2002
- MSF - Machinery Fault Simulator. Disponível em: <www02.smt.ufrj.br/~offshore/mfs/index.html#TOC1>. Acesso em: 01 abr. 2019
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO10816-1 - Mechanical vibration**: Evaluation of machine vibration by measurements on non-rotating parts. San Diego,CA: Machinery Information Management Open Systems Alliance (MIMOSA), 7-13, 1995.
- MENNA. Alexandre Ribeiro, **Detecção de falhas em mancais de rolamento por análise de vibrações em banda larga**: Um caso prático de aplicação em uma população de equipamentos rotativos. Porto Alegre:, 14 2007.
- A. P Braga, A. P. L. F. de Carvalho e T. B. Ludemir, **Redes Neurais Artificiais**: Teoria e aplicações. Rio de Janeiro (LTC): 15-17 2000.