

NOVA METODOLOGIA PARA PREVISÃO DE VIDA ÚTIL REMANESCENTE DE ROLAMENTOS

Letícia Lorena Conceição Araújo ⁽¹⁾ (leticia.conceicao@ufu.br), Lucas Costa Brito ⁽²⁾ (lucas.brito@ufu.br), Julia Bertelli Duarte ⁽³⁾ (julia.duarte@uftm.edu.br), Marcus Antônio Viana Duarte ⁽⁴⁾ (mvduarte@ufu.br)

⁽¹⁾ Universidade Federal de Uberlândia, Av. João N. Avila, 2121, Uberlândia, Brasil (UFU); Laboratório de Acústica e Vibração (LAV);

⁽²⁾ Universidade Federal do Triângulo Mineiro, Avenida Doutor Randolpho Borges Júnior, 1250, Uberaba, Brasil (UFTM);

RESUMO: *Manutenção preditiva é uma técnica que visa por meio do monitoramento do maquinário prever o tempo de vida remanescente e com isso evitar falhas catastróficas que possam vir a prejudicar o processo. Contudo, as estratégias mais utilizadas atualmente empregam machine learning, que, por sua vez, exige a rotulação dos dados e muitas amostras para ser bem-sucedida, ferramentas que não estão sempre disponíveis. No intuito de suprir essa deficiência o presente trabalho propõe uma metodologia estatística para prever o tempo de vida de rolamentos sem precisar de aprendizado de máquina. O procedimento realizado consiste na extração de parâmetros do banco de dados, identificação do parâmetro que possui maior aderência à uma distribuição Weibull e previsão de tempo de vida limite por meio desta distribuição probabilística. Foram analisados 3 rolamentos, dois monitorados por 15560 minutos e o terceiro por 9840 minutos, sendo que o primeiro parou de ser monitorado antes da falha enquanto os outros dois foram monitorados até a falha. Os resultados obtidos previram que os rolamentos teriam uma vida útil de 21050, 14820 e 9640 minutos, respectivamente, mostrando que a metodologia usada atende a demanda de uma previsão de vida com boa precisão, rápida e conservadora.*

PALAVRAS-CHAVE: *Vida Útil Remanescente, Rolamentos, Distribuição Weibull.*

NEW METHODOLOGY FOR PREDICTING REMAINING USEFUL LIFE OF BEARINGS

ABSTRACT: *Predictive maintenance is a technique that aims to predict the remaining life of a machine by monitoring it and thus avoid catastrophic failures that could harm the process. However, the most widely used strategies currently employ machine learning, which, in turn, requires data labeling and many samples to be successful, tools that are not always available. To overcome this deficiency, this work proposes a statistical methodology to predict the lifespan of bearings without the need for machine learning. The procedure performed consists of extracting parameters from the database, identifying the parameter that has the greatest adherence to a Weibull distribution and predicting the limit lifespan using this probabilistic distribution. Three bearings were analyzed, two monitored for 15560 minutes and the third for 9840 minutes, while the first one, stopped being monitored before failure, the other two were monitored until failure. The results obtained predicted that the bearings would have a useful life of 21050, 14820 and 9640 minutes, respectively, showing that the methodology used meets the demand for a life prediction with good precision, quickness and in a conservative range.*

KEYWORDS: *Remaining Useful Life, Bearings, Weibull Distribution.*

1. INTRODUÇÃO

1.1. Revisão bibliográfica e objetivo

Rolamentos são os elementos de máquinas que falham com maior frequência em âmbito industrial, assim existe uma grande quantidade de trabalhos desenvolvidos com o intuito de prever o fim de vida desse componente. Analisado a literatura é visível que entre as abordagens modernas para previsão de vida útil de rolamentos, destacam-se o papel do aprendizado de máquina e da inteligência artificial na manutenção preditiva. Eles exploram redes neurais profundas, como LSTM e Transformer, que capturam informações temporais críticas para melhorar a precisão das previsões ao lidar com dados complexos e volumosos. A evolução das fórmulas de vida dos rolamentos ao longo do tempo é discutida, enfatizando a adaptação dessas fórmulas às normas internacionais modernas e a importância de integrar propriedades dos materiais nas previsões. Os algoritmos de aprendizado por transferência são destacados por sua capacidade de adaptar modelos previamente treinados a novos cenários industriais, melhorando a eficiência preditiva. Além disso, o uso de aprendizado profundo para prever a vida remanescente dos rolamentos, com um foco especial em redes neurais convolucionais, é investigado (Tang, 2022; Jiang, 2022; Kuzmanovic, 2024; Liu, 2021).

Os métodos híbridos que combinam características de tempo-frequência com aprendizado profundo são destacados por sua eficácia sob condições operacionais variáveis. Modelos baseados em CNN-LSTM-AM são introduzidos, utilizando mecanismos de atenção para aumentar a precisão na previsão de falhas. A integração de conhecimento físico em redes neurais é proposta para considerar variáveis físicas nas estimativas de vida útil, evitando erros. As redes estruturadas densas oferecem previsões precisas em aplicações industriais, e a relevância de modelos precisos e adaptáveis é reafirmada, capazes de serem aplicados em diferentes cenários industriais para aumentar a confiabilidade e eficiência dos sistemas modernos (Sun, 2020; Zhang, 2021; Xia, 2021; Wang, 2021).

A integração de redes neurais com algoritmos clássicos, como o uso de redes de suporte vetorial, é explorada, mostrando melhorias na previsão de falhas em rolamentos. Estudos de caso destacam a eficácia de diferentes abordagens em cenários reais, demonstrando como a combinação de técnicas pode aumentar a precisão das previsões de vida útil. A importância de métodos que não dependem exclusivamente de dados rotulados é discutida, enfatizando a necessidade de soluções que ofereçam previsões rápidas e conservadoras. A diversidade de abordagens reflete um campo em constante evolução, que busca unir inteligência artificial com conhecimentos de engenharia para otimizar a manutenção preditiva e aumentar a confiabilidade dos sistemas industriais (Zhou, 2020; Tang, 2022; Liu, 2021).

Analisando todos esses métodos, é possível perceber que a falta de dados seria um problema para a implementação dessas propostas em um ambiente industrial. Assim o presente trabalho

pretende realizar a previsão de vida dos rolamentos de maneira puramente estatística sem a necessidade de rotulação e volume de dados para operar. Utilizando a distribuição probabilística Weibull, muito usada para modelar falhas na literatura.

1.3. Distribuição Weibull

O modelo de Weibull é amplamente utilizado para a análise de dados de vida útil e previsão de falhas em componentes mecânicos. A distribuição Weibull é definida por sua função de densidade de probabilidade, que pode ser usada para modelar a probabilidade de falha ao longo do tempo, permitindo a previsão do tempo restante até a falha de um componente. O uso da distribuição de Weibull na manutenção preditiva de rolamentos, por exemplo, auxilia na programação de intervenções antes que ocorram falhas críticas.

A função de densidade de probabilidade da distribuição Weibull é expressa pela Equação (1):

$$f(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^{\beta}} \quad (1)$$

Onde:

- t é o tempo;
- β é o parâmetro de forma;
- η é o parâmetro de escala.

A função de confiabilidade, que representa a probabilidade de um componente não falhar até o tempo t , é dada pela Equação (2):

$$R(t) = e^{-\left(\frac{t}{\eta}\right)^{\beta}} \quad (2)$$

Onde $R(t)$ é a função de confiabilidade.

Assim, dado um parque de máquinas rotativas semelhantes (bombas, motores e geradores eólicos, por exemplo) onde algum parâmetro vibratório é monitorado, torna-se possível definir um valor limite do parâmetro a partir da premissa de que se a máquina está funcionando, ela não falhou (no tempo presente). Por se tratar de uma possibilidade binária de falha ou não falha, pode-se modelar o problema utilizando o teste hipótese Newman-Pearson, sendo $H_0: \theta = \theta_0$ e $H_1: \theta = \theta_1$. Para o teste, rejeita H_0 de acordo com Eq. (3).

$$\Lambda(X) = \frac{L(x|\theta_0)}{L(x|\theta_1)} \leq \eta, \text{ em que, } P(\Lambda(X) \leq \eta|H) = \alpha \quad (3)$$

onde α é o nível de significância para o limite η .

Dado a probabilidade A de que ocorram intervenções desnecessárias e a probabilidade de que a intervenção é necessária P_g , a relação constitutiva do método de Newman-Person pode ser calculada de acordo com Eq. (4).

$$A = P_g \int_{S_b}^{\infty} p(S) dS \quad (4)$$

onde S_b é o valor limite do parâmetro vibratório S e p é a função densidade de probabilidade.

Uma das maneiras de estimar o valor de S_b é utilizar a desigualdade de Chebyshev para a estimativa da probabilidade de exceder o valor de ruptura Cenpel (1990), de acordo com Eq. (5).

$$S_b \leq \bar{S} + \sigma_s \sqrt{\frac{P_g}{2A}} \quad (5)$$

onde, S_b é o valor limite para o parâmetro, $\bar{S}$ é o valor médio amostral (temporal e espacial) do parâmetro vibratório medidos nas máquinas e σ_s é o desvio padrão amostral dos parâmetros.

Uma vez definido o valor limite para a falha, a previsão para o tempo da falha pode ser obtido via ajuste dos parâmetros de uma distribuição estatística para a evolução temporal dos sintomas da máquina de interesse e determinar o tempo que o sintoma levará para atingir S_b .

2. MATERIAIS E MÉTODOS


2.1. Banco de dados

Para validação da metodologia utilizou-se um banco de dados clássico de falhas em rolamentos desenvolvido por Qiu et al. (2006) e disponibilizado pela NASA (Administração Nacional da Aeronáutica e Espaço). Foram utilizados 3 testes, sendo pertencentes aos conjuntos 01 e 02 do banco de dados:

- Conjunto 1: defeito na pista interna no rolamento 3.
- Conjunto 1: defeito no elemento rolante do rolamento 4.
- Conjunto 2: falha na pista externa do rolamento 1.

Para a criação do banco de dados a velocidade de rotação foi mantida constante em 2.000 rpm no motor acoplado ao eixo por meio de correias. Uma carga radial de 6.000 lb foi aplicada ao eixo e ao rolamento por um mecanismo de mola. Todos os rolamentos foram lubrificados. Rolamentos de duas carreiras Rexnord ZA-2115 foram instalados no eixo como mostra a Figura 1. Acelerômetros ICP de quartzo de alta sensibilidade PCB 353B33 foram instalados na carcaça do rolamento, dois acelerômetros para cada rolamento (eixos x e y) do conjunto de dados 1 e um acelerômetro para o conjunto de dados 2.

FIGURA 1. Bancada de ensaio.



Fonte: QIU (2006).

2.2. Metodologia

Inicialmente, o sinal de vibração foi processado extraindo parâmetros comumente utilizados em manutenção preditiva no domínio do tempo e frequência. Os parâmetros utilizados foram: valor RMS, pico, pico a pico, curtose, fator de crista, valor de amplitude em BPFI (frequência de falha na pista interna), BPFO (frequência de falha na pista externa) e BSF (frequência do elemento rolante). Para a fórmula de cálculo detalhado se referir a Brito et al. (2021).

Após extração dos parâmetros, eles são ajustados a distribuição Weibull, sendo o parâmetro que obteve maior aderência a Weibull o utilizado para seguir as etapas abaixo:

Etapa 1: utilizando os históricos de todos os testes se calcula de forma aleatória (temporal e espacial) 100 valores de S .

Etapa 2: com os valores de S são estimados os valores de $\bar{S}$ e σ_S para o parâmetro.

Etapa 3: estima-se S_b utilizando a Eq. (5) para um valor de P_g igual a 90% e A de 1%.

Etapa 4: utilizando os valores dos parâmetros a partir do momento em que o defeito foi reportado (frequência de falha foi detectada) até o momento em que o parâmetro aumento aproximadamente 5 vezes, ajusta-se os parâmetros da distribuição de Weibull generalizada dada pela Equação 6 (WU, 2017).

$$S(t) = H + K \frac{\beta}{\alpha^\beta} t^{\beta-1} \quad (6)$$


onde além dos parâmetros de escala α e de forma β são introduzidas as constantes H e K para adequação da distribuição.

Etapa 5: Utilizando um procedimento para determinar os zeros da função, o tempo para atingir o valor limite para o parâmetro S_b é calculado.

3. RESULTADOS

O sinal temporal completo para os bancos de dados analisados é apresentado na Figura 2.


FIGURA 2. Sinal temporal: (a) 03/01, (b) 04/01, (c) 01/02..




Fonte: Própria (2024).


Os parâmetros normalizados calculados para todos os sinais são mostrados na Figura 3 abaixo.

FIGURA 3. Parâmetros extraídos: (a) 03/01, (b) 04/01, (c) 01/02.





(b)



(c)

Fonte: Própria (2024).

Os parâmetros que melhor tiveram aderência a Weibull e o momento em que foram detectados se encontra na Tabela 1 abaixo.

TABELA 1. Aderência a Weibull.

Rolamento	Melhor aderência	Deteção inicial
03/01	BPFI	1556
04/01	BSF	1464
01/02	BPFO	532

Fonte: Própria (2024).

Utilizando os parâmetros com melhor aderência informados na Tabela 1 acima, calculou-se a estimativa de vida remanescente apresentada na Tabela 2 abaixo.

TABELA 2. Previsão de vida.

Rolamento	Valor limite [S_f]	Previsão [minutos]	Tempo em operação [minutos]	Parou
03/01	1,8	21 050	15 560	Antes da falha
04/01	4,4	14 820	15 560	Pela falha
01/02	6,0	9 640	9 840	Pela falha

Fonte: Própria (2024)

Como pode ser observado na Tabela 2, o Rolamento 3 do Conjunto 1 teve seu monitoramento interrompido antes da falha, assim embora tenha operado apenas 15 560 minutos poderia continuar operando até os 21 050 minutos como mostra a previsão. O Rolamento 4 do Conjunto 1 parou de ser monitorado por falha tendo uma operação de 15 560 minutos enquanto a técnica sendo mais conservadora previu 14 820 minutos, uma diferença de 740 minutos (12 horas e 20 minutos). Enquanto o Rolamento 1 do Conjunto 2, que apresentou melhor resultado, operou por 9 840 minutos até a falha e teve seu tempo de vida estimado conservadoramente de 9640 minutos, uma diferença de 200 minutos (3 horas e 20 minutos).

4. CONCLUSÃO

Por fim, os valores obtidos para a previsão da vida remanescente demonstram que a metodologia foi capaz de prever com segurança o fim de vida dos componentes, e para o caso em que o teste foi parado antes da falha, a previsão indicou a possibilidade de continuação da utilização do rolamento apesar do defeito presente (conforme constatado na documentação do banco de dados).

AGRADECIMENTOS

Os autores agradecem as agências de fomento CNPq e CAPES, e também a empresa PETROBRAS pelo suporte financeiro no desenvolvimento do trabalho. Assim, como as instituições que fazem parte, a Universidade Federal de Uberlândia (UFU), principalmente ao Laboratório de Acústica e Vibrações (LAV) e a Universidade de São João Del Rey.

DECLARAÇÃO DE RESPONSABILIDADE

Os autores são os únicos responsáveis por este trabalho.

REFERÊNCIAS

BRITO, L.C., Gomes, M.C., Oliveira, D., Silva, M.B. and Duarte, M.A.V., 2023a. ‘Vibration features for indirect monitoring of end micromilling process’, *Precision Engineering* Vol. 79, pp. 7-15.

CEMPEL, C. 1990. “Limit value in the practice of machine vibration diagnostics”. *Mechanical Systems and Signal Processing* Volume 4, Pages 483-493.

JIANG, Jun; et al. A Review of Methods for Remaining Useful Life Prediction of Motor Bearings. *The International Journal of Advanced Manufacturing Technology*, [s. l.], v. 122, p. 345–368, 2022. DOI: 10.1007/s00170-021-07318-3.

KUZMANOVIC, Slavko; et al. From Innovation to Standardization—A Century of Rolling Bearing Life Formula. *Machines*, [s. l.], v. 12, n. 7, p. 444, 2024. DOI: 10.3390/machines12070444.

LIU, Yingchao; et al. Transfer learning algorithms for bearing remaining useful life prediction: A comprehensive review from an industrial application perspective. *Mechanical Systems and Signal Processing*, [s. l.], v. 148, p. 107142, 2021. DOI: 10.1016/j.ymssp.2020.107142.

QIU, H., Lee, J., Lin, J. 2006. Wavelet Filter-based Weak Signature Detection Method and its Application on Roller Bearing Prognostics. *Journal of Sound and Vibration* 289, 1066-1090.

SUN, Cheng; et al. Remaining Useful Life Prediction of Rolling Element Bearings Using Deep Learning. *Energies*, [s. l.], v. 13, n. 5, p. 1212, 2020. DOI: 10.3390/en13051212.

TANG, Xinglu; et al. Rolling Bearing Remaining Useful Life Prediction Based on LSTM-Transformer Algorithm. *The International Journal of Advanced Manufacturing Technology*, [s. l.], v. 121, p. 1293–1310, 2022. DOI: 10.1007/s00170-021-07872-8.

TANG, Xinglu; XI, Hui; CHEN, Qianqian; LIN, Tian Ran. Remaining Useful Life Prediction for Rolling Element Bearings. *Machines*, [s. l.], v. 12, n. 7, p. 444, 2024. DOI: 10.3390/machines12070444.

WANG, Jia; et al. Life Prediction Method of Rolling Bearing Based on CNN-LSTM-AM. *Journal of Vibroengineering*, [s. l.], v. 23, n. 5, p. 1134–1147, 2021. DOI: 10.21595/jve.2021.21553.

WU, B., Li, W., Qiu, M., 2017. “Remaining Useful Life Prediction of Bearing with Vibration Signals Based on a Novel

Indicator”. *Shock and Vibration*.

XIA, Ming; et al. Hybrid deep learning-based remaining useful life prediction of rolling element bearings using time–frequency features. *The International Journal of Advanced Manufacturing Technology*, [s. l.], v. 118, n. 9–10, p. 2693–2704, 2021. DOI: 10.1007/s00170-021-07674-0.

ZHANG, Lei; et al. Dense-Structured Network Based Bearing Remaining Useful Life Prediction System. *Computer Modeling in Engineering & Sciences*, [s. l.], v. 129, n. 2, p. 589–604, 2021. DOI: 10.32604/cmes.2021.15130.

ZHOU, Wei; et al. Physics guided neural network: Remaining useful life prediction of rolling element bearings. *Mechanical Systems and Signal Processing*, [s. l.], v. 140, p. 106683, 2020. DOI: 10.1016/j.ymssp.2020.106683.