文章编号:1674-7607(2026)02-0157-07 DOI:10.19805/j.cnki.jcspe.2026.240756

考虑运行特性的风电齿轮箱轴承劣化态势感知

赵洪山[1]， 张一波[1]， 林诗雨[1]， 张绣梅[1]， 张扬帆[2]， 杨伟新[1,2]
(1. 华北电力大学 电力工程系,河北保定 071003； 2. 国网冀北电力有限公司科学研究院,北京 100045)

摘 要: 提出了一种考虑风机运行特性的劣化态势感知算法。首先,提出了一种基于损伤累积理论的动力学劣化态势指标,通过 Hertz 理论计算轴承劣化度(DL);其次,提出了一种结合混合长短期记忆(LSTM)-CatBoost 预测器(HLCP)的劣化预测方法,通过引入轴承转速作为时间序列输入的方法,考虑风机运行特性的影响,预测劣化度增长值;基于仿真模型计算轴承损伤临界值,从而预测轴承剩余寿命;最后,使用我国北方某风电场的振动和数据采集与监视控制系统(SCADA)数据进行验证。结果表明:所提出的劣化态势指标在预测趋势与历史趋势上的相似度约为 74.42%,具有明显的趋势性和单调性;基于 HLCP 模型得到的剩余寿命预测结果与实际失效时间的误差仅为 640 h,相较于未考虑风机运行特性的预测方法,误差减少了 16 461 h。

关键词: 劣化指标; 劣化态势感知; 高速轴承; LSTM-CatBoost; Hertz
中图分类号:TH315 **文献标志码:**A **学科分类号:**510.80

Deterioration Trend Perception of Wind Turbine Gearbox Bearings Considering Operational Characteristics

ZHAO Hongshan[1], *ZHANG Yibo*[1], *LIN Shiyu*[1], *ZHANG Xiumei*[1], *ZHANG Yangfan*[2], *YANG Weixin*[1,2]
(1. Department of Power Engineering, North China Electric Power University, Baoding 071003, Hebei Province, China; 2. State Grid Jibei Electric Power Co., Ltd. Electric Power Science Research Institute, Beijing 100045, China)

Abstract: A deterioration trend perception algorithm considering the operating characteristics of wind turbines was proposed. Firstly, a kinetic deterioration state indicator based on damage accumulation theory was proposed, and the bearing deterioration level (DL) was calculated by Hertz theory. Secondly, a hybrid long short-term memory (LSTM)-CatBoost predictor (HLCP) deterioration prediction method was proposed. The deterioration growth value was predicted by considering the influence of wind turbine operating characteristics and introducing the bearing speed as a time series input. Then, the critical value of bearing damage was calculated based on the simulation model, so as to predict the remaining bearing life. Finally, it was validated using the vibration and supervisory control and data acquisition (SCADA) data from a wind farm in the north of China. Results show that the proposed deterioration state indicator has a similarity of about 74.42% in predicting trend and historical trend, with obvious trend and monotonicity.

收稿日期:2024-12-05 **修订日期:**2024-12-24
基金项目:国网冀北电力有限公司电力科学研究院科学技术资助项目(52018K22001P)
作者简介:赵洪山(1965—),男,北京人,教授,博士生导师,研究方向为电力系统动态分析与控制、主动配网以及故障预测等,E-mail:zhaohshcn@126.com。

The error between the remaining life prediction results obtained based on the HLCP model and the actual failure time is only 640 h, which is 16 461 h less compared to the prediction method that does not take into account the turbine's operating characteristics.

Key words: degradation index; degradation trend perception; high-speed bearing; LSTM-CatBoost; Hertz

风电机组长期运行在恶劣环境下,受极端天气和负载的影响,其组件性能呈逐渐下降的趋势。性能劣化会导致组件温度升高、振幅增大,从而导致设备故障率上升,最终导致风电机组失效[1]。风电机组高速轴承在运行过程中由于具有更高的转速使其更容易发生劣化。目前齿轮箱故障造成的停机时间约占总停机时间的 19.4%,其中 50%以上的情况是由高速轴承失效引起的[2-4]。因此,准确评估和预测风电机组齿轮箱高速轴承的劣化程度对指导运维具有重要意义。

为了准确评估轴承的劣化程度,需要构建一个可靠的劣化态势指标。由于机器学习算法的广泛应用,目前劣化指标的构建方法大多集中在数据驱动型上[5]。文献[6]提出了一种结合鹈鹕优化算法、变分模态分解和自编码器的风机轴承劣化指标构建方法。文献[7]提出了一种基于二维隐马尔科夫模型的负对数似然概率退化指标构建方法。文献[8]基于主成分分析对 35 个性能退化指标进行融合,以构建一个综合退化指标。文献[9]提出了一个基于多通用特征的退化性能指标。上述文献需通过大量数据构建退化指标。但是,数据驱动法往往需要轴承全寿命周期数据,而当前风机齿轮箱高速轴承的实际全寿命周期劣化数据较为稀缺,导致数据驱动法实际应用困难。而构建物理劣化态势指标可以解决数据驱动型的数据依赖问题,并提高劣化态势指标的可解释性[10]。

此外,为了准确预测劣化发展趋势,需要构建一个高精度的预测模型。文献[11]提出了利用高斯过程回归来预测退化趋势的方法。文献[12]提出了使用人工神经网络模型预测退化趋势的方法。文献[13]提出了一种通过双向长短期记忆网络(BiLSTM)模型预测退化趋势的方法。文献[14]提出了一种基于 Paris 公式相关轴承劣化理论和扩展卡尔曼滤波结合的剩余寿命预测模型。文献[15]提出了一种应用改进的集合经验模态分解(EEMD)和时间序列神经网络相结合的预测模型。然而上述方法未考虑动态运行工况对于预测结果的影响,可能出现预测精度无法满足实际预测任务需求的问题。

为解决上述问题,本文提出了一种考虑风机运行特性的劣化态势感知算法,首先从轴承振动机理角度出发,提出了一种基于损伤累积理论的动力学劣化态势指标构建方法。该方法基于 Hertz 接触理论构建了单自由度动力学方程,用于计算瞬态应力幅值。根据仿真得到的损伤临界值,构建了劣化态势指标(DL)$D(t)$,然后结合风电机组特有的运行特性,提出了一种基于混合长短期记忆(LSTM)-CatBoost 预测器(HLCP)的劣化度增长值预测模型。该模型包含 2 个阶段:第 1 阶段采用混合长短期记忆(LSTM)模型,学习齿轮箱高速轴承转速的周期性特点;第 2 阶段选择 CatBoost 算法,学习齿轮箱高速轴承转速和劣化态势指标增长值(ΔD)之间的相关特性。最后,采用我国北方某风电场的振动和数据采集与监视控制系统(SCADA)数据进行实例验证。

1 劣化态势指标的构建

1.1 基于损伤累积理论构建的轴承劣化态势指标

轴承间接触振动的持续作用引发磨损、点蚀等损伤,这是导致轴承劣化的根本原因[16],损伤累积理论认为材料的损伤是由多次应力的累积作用导致的[17]。由于物理损伤不可逆,所以接触振动对轴承造成的损伤有累积效应,因此采用累积损伤理论来表征轴承的劣化过程,构建轴承的动力学劣化态势指标 $D(t)$。

$$D(t)=\sum_{1}^{N}\frac{F_N\Delta T_N}{D_{\max}} \tag{1}$$

式中:F_N 为第 N 个应力的幅值;ΔT_N 为第 N 个应力的作用时间;$D_{\max}$为材料能承受的损伤临界值。

由于缺乏风电机组齿轮箱高速轴承全寿命周期劣化数据,因此大多数研究通过仿真模拟来获得疲劳寿命数据[18]。本文采用 ANSYS 软件进行仿真模拟,以确定损伤临界值。

1.2 基于 Hertz 接触理论计算瞬态应力幅值

深沟球轴承结构简单,适用于高速场合,在大型风电机组中被广泛用作齿轮箱高速轴承[19]。因此,本文研究轴承局部点接触情况,且内部接触问题满足 Hertz 接触理论的各种假设,因此根据该理论可得两物体点接触时的载荷 F 与位移关系[20]为

$$F=K\delta^{1.5} \tag{2}$$

式中：K 为接触刚度；δ 为弹性形变量。

钢制轴承接触刚度的一般表达式为

$$K=2.15\times10^5\sum\gamma^{-0.5}\alpha^{-1.5} \tag{3}$$

式中：$\sum\gamma$ 为接触物体曲率和；α 为接触变形系数。

轴承总的接触刚度 K_t 为

$$K_t=\frac{1}{(1-K_{in}^{2/3}+1K_o^{2/3})^{3/2}} \tag{4}$$

式中：K_{in} 为内圈接触刚度；K_o 为外圈接触刚度。

本文建立轴承动力学模型时进行如下假设：忽略加工误差的影响；滚动体均匀分布，滚动时不打滑；仅考虑滚动体与滚道间的局部形变；轴承恒温旋转，不考虑润滑等影响因素。

基于上述假设，滚动体与滚道的接触等效为线性弹簧，外圈相对于地面固定不动，将内圈与轴看成一个整体旋转，如图 1 所示。其中，θ_i 为第 i 个滚动体在 t 时刻的角位置，β 为轴承承载区分布范围角。

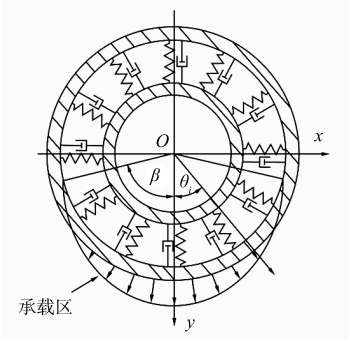


图 1　简化后的轴承动力学模型

Fig. 1　A simplified model of bearing dynamics

基于牛顿第三定律分析轴承整体。鉴于实际工程中仅安装了径向振动传感器，本文建立了单自由度的动力学模型。

$$m_i\ddot{x}+c\dot{x}+\sum_{i=1}^{n}(\xi K_t\delta_i^{1.11}\cos\theta_i)=F \tag{5}$$

式中：m_i 为内圈与轴的总质量；c 为线性化阻尼系数；n 为滚动体数量；ξ 为判断滚动体与滚道接触情况的参数；δ_i 为第 i 个滚动体与滚道的接触形变量；x 为轴承位移。

根据 Hertz 理论，滚动体与轴承间的接触应力 F_N 为

$$F_N=\frac{3F}{2\pi a^2} \tag{6}$$

式中：a 为接触区半径。

1.3　基于 ANSYS 仿真确定的损伤临界值

为了得到损伤临界值和轴承失效时刻 e_{STD}，采用 ANSYS 软件模拟风电机组齿轮箱高速轴承的运行工况，直至失效，损伤临界值 D_{max} 为

$$D_{max}=\bar{F}_{max}T \tag{7}$$

式中：$\bar{F}_{max}$ 为最大平均接触应力；T 为运行时间。

通过模拟旋转过程中的接触摩擦，符合 Hertz 理论中假设要求，设置额定转速，通过加入 N-S 曲线求解获得相应的接触应力以及寿命时间，由此获得损伤临界值和轴承失效时刻。仿真预测轴承失效时刻为 20321209T000000，损伤临界值为 2.904×10^9 N·s。图 2 和图 3 分别为仿真模拟轴承滚动体等效应力和疲劳寿命的结果。

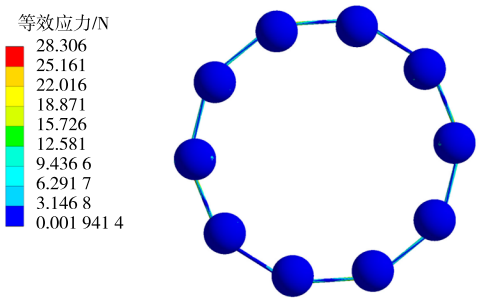


图 2　滚动体等效应力仿真结果

Fig. 2　Simulation results of equivalent stress of rolling elements

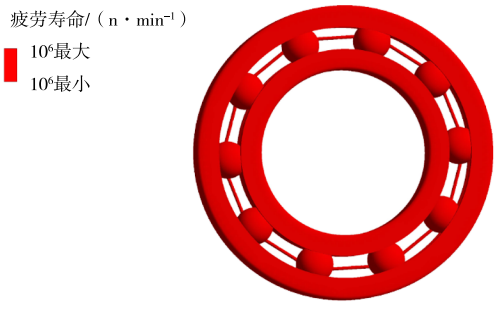


图 3　疲劳寿命仿真结果

Fig. 3　Simulation results for fatigue life prediction

2　考虑运行特性影响的劣化态势感知预测模型

2.1　运行特性

风电机组齿轮箱高速轴承转速与劣化速度直接相关[21]，轴承在高速运转时承受更大的机械应力和摩擦力，导致劣化加速，因此本文考虑了转速变化对劣化的影响。

$$n(R)\propto\Delta D \tag{8}$$

$$\Delta D=D(t)-D(t-1) \tag{9}$$

式中：$n(R)$ 为轴承转速。

2.2　HLCP 预测模型的构建

结合运行特性的时变特点，本文提出了 LSTM-

CatBoost 预测器用于实时劣化预测。由于实时劣化预测任务中转速和日期数据存在时序关系，为了兼顾准确性和高效性，因此采用 LSTM 网络模型[22]学习风速的周期性特点。为了整合时序和非时序特征，提高预测性能，引入了 CatBoost 算法，学习转速对劣化速度的影响。

HLCP 模型结构如图 4 所示。首先，使用 LSTM 网络对风电机组 SCADA 数据进行深度学习，以提取转速与日期之间的周期性关系。其次，采用 CatBoost 算法进行回归学习，以探究转速对 ΔD 的影响。最后，通过模型链将前者的输出连接到后者的输入上，实时更新数据集的同时，基于历史和预测的转速数据对未来 ΔD 变化趋势进行预测。

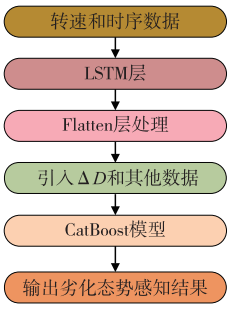


图 4 HLCP 模型结构

Fig. 4 HLCP model structure diagram

2.3 考虑运行特性影响的劣化态势感知

2.3.1 考虑运行特性影响的劣化预测

由于全寿命周期劣化数据的缺失以及运行工况的时变特性，为了得到更符合实际的劣化曲线，利用 HLCP 预测模型对劣化度发展趋势进行实时预测，预测流程如图 5 所示。

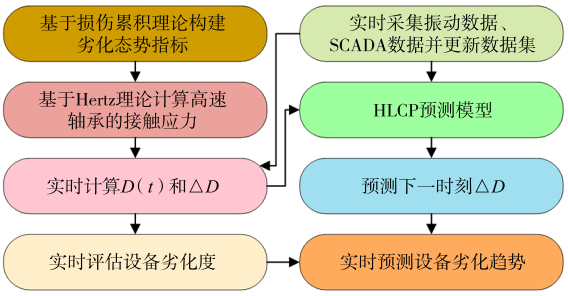


图 5 考虑运行特性影响的劣化态势感知预测流程图

Fig. 5 Flowchart of degradation trend perception prediction considering the influence of operational characteristics

由图 5 可见，首先基于损伤累积理论构建劣化态势指标 $D(t)$，并使用 Hertz 理论实时计算瞬态应力幅值。其次，利用实时采集的振动数据计算设备 $D(t)$ 和 ΔD，然后使用这些数据以及转速数据来训练 HLCP 预测模型。随后，通过计算得到的 $D(t)$ 实时评估设备劣化度。最后，使用 HLCP 预测模型连续预测未来时刻的 ΔD。

2.3.2 考虑运行特性影响的剩余寿命预测

轴承劣化态势指标 $D(t)$ 的取值区间为[0,1]，其反映了轴承劣化程度，当劣化态势指标达到 1 时即视为失效。

利用式(10)预测轴承剩余寿命。

$$e_o=\frac{1-D(0)}{\overline{\Delta D}}\cdot\Delta T_N \tag{10}$$

$$\begin{cases}\Delta D_1+\Delta D_2+\cdots+\Delta D_s=1\\ e_v=s\cdot\Delta T_N\end{cases} \tag{11}$$

式中：$D(0)$ 为初始劣化度；$\overline{\Delta D}$ 为历史平均劣化度增幅；ΔD_s 为未来 s 个劣化度增幅；e_o 为未考虑运行特性影响的剩余寿命预测结果；e_v 为考虑运行特性影响的剩余寿命预测结果。

3 算例仿真验证

3.1 试验概况

选取国内北方某风电场某机组 2023 年 1 月到 2023 年 12 月整年的实际运行 SCADA 数据和 2023 年 10 月到 2023 年 12 月的振动数据进行实例验证。该风电机组 SCADA 数据采样时间间隔为 15 min，振动数据采样频率为 64 kHz；切入、切出风速分别为 3 和 25 m/s，额定功率为 2 MW。本文所提 HLCP 预测模型输入为过去 24 h 的转速数据，输出为下一时刻的 ΔD，训练集和测试集的比例分别为 80% 和 20%。

为了全面评估所构建的风电机组齿轮箱高速轴承动力学劣化态势指标 $D(t)$ 的优势，采用趋势性和单调性[23]的评价准则。

为了准确分析 HLCP 预测模型的性能，选用均方误差(MSE)K_{MSE}、均方根误差(RMSE)K_{RMSE}、平均绝对误差(MAE)K_{MAE} 和拟合优度 R^2 作为预测性能评价指标。

$$K_{\mathrm{MSE}}=\frac{1}{n}\sum_{i=1}^{n}(Y_i-\hat{Y}_i)^2 \tag{12}$$

$$K_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(Y_i-\hat{Y}_i)^2} \tag{13}$$

$$K_{\mathrm{MAE}}=\frac{1}{n}\sum_{i=1}^{n}|Y_i-\hat{Y}_i| \tag{14}$$

$$R^2=1-\frac{\sum_{i=1}^{n}(Y_i-\hat{Y}_i)^2}{\sum_{i=1}^{n}(Y_i-\bar{Y})^2} \tag{15}$$

式中：Y_i 为第 i 个真实观测值；$\hat{Y}_i$ 为第 i 个预测值；$\bar{Y}$ 为所有观测值的平均值。

为了评价所提模型劣化度预测结果的准确性，选用剩余寿命相对误差 Δe 作为评估指标。

$$\Delta e = |e_{\mathrm{M}} - e_{\mathrm{STD}}| \tag{16}$$

式中：e_{M} 为预测所得剩余寿命；e_{STD} 为仿真模拟所得剩余寿命真实值。

3.2　劣化态势指标性能分析

通过比较历史数据与预测数据的趋势相似度来进行趋势性分析。趋势相似度的计算公式如下：

$$l_{\mathrm{Ts}} = \left| \frac{l_{\mathrm{Ps}}}{l_{\mathrm{Hs}}} \right| \times 100\% \tag{17}$$

式中：l_{Ts} 为趋势性相似度；l_{Ps} 为预测数据线性回归斜率；l_{Hs} 为历史数据线性回归斜率。

趋势性分析结果中，历史趋势斜率为 $1.654\,1\times10^{-5}$，预测趋势斜率为 $1.230\,9\times10^{-5}$。计算所得趋势相似度为 74.42%，这表明历史趋势与预测趋势之间存在较高的相似度，这表明模型在一定程度上准确地预测了劣化趋势，但仍存在一定差距，这可能是由于历史数据样本不足。单调性分析结果如图 6 所示。由图 6 可见，所构建的动力学劣化态势指标 $D(t)$ 具有明显的单调性，这说明模型在连续预测中能保持一致的增长趋势。

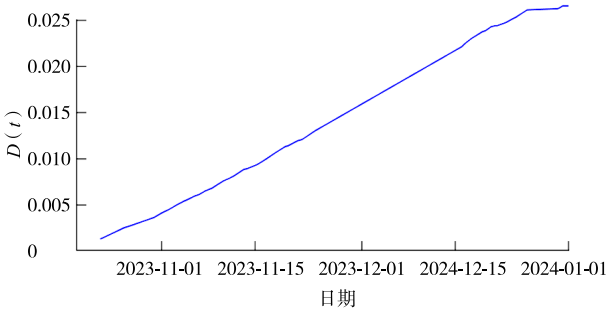


图 6　$D(t)$ 曲线图

Fig. 6　$D(t)$ curve

3.3　HLCP 预测模型性能分析

为验证 HLCP 预测模型的预测性能，本文对比了 XGBoost、随机森林回归、梯度提升回归树和 LightGBM 的预测效果，对比结果如表 1 所示。

表 1　不同预测模型的预测性能

Tab. 1　Performance assessment of different degradation prediction models

模型	MSE	RMSE	MAE	R^2
HLCP	$4.964\,6\times10^{-12}$	$2.228\,1\times10^{-6}$	$1.474\,8\times10^{-6}$	0.904 0
XGBoost	$5.713\,4\times10^{-11}$	$2.672\,1\times10^{-5}$	$6.312\,7\times10^{-6}$	−0.009 5
随机森林回归	$2.298\,3\times10^{-11}$	$1.253\,1\times10^{-5}$	$2.815\,3\times10^{-6}$	0.735 2
梯度提升回归树	$2.597\,4\times10^{-11}$	$1.158\,3\times10^{-5}$	$3.179\,3\times10^{-6}$	0.700 7
LightGBM	$1.263\,1\times10^{-11}$	$8.648\,1\times10^{-5}$	$2.269\,4\times10^{-6}$	0.776 8

由表 1 可知，HLCP 模型在各项指标上都表现出色。这是因为所提出的模型中使用了 CatBoost 算法，其具有高性能的学习能力。因此，R^2 提升至 0.904，说明该模型非常适合实现劣化态势感知的预测任务。

3.4　劣化预测曲线分析

本文通过对比考虑运行特性影响的模型（HLCP）和未考虑运行特性影响的模型，以及其他算法模型来评估预测性能，结果如图 7 所示。

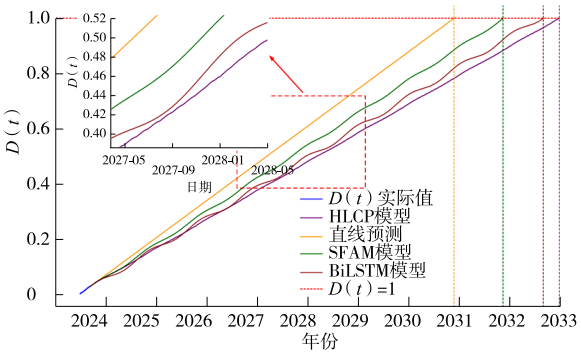


图 7　劣化态势感知预测结果

Fig. 7　Degradation trend perception prediction results

由图 7 可见，未考虑运行特性影响的预测方法无法反映风电机组的运行特性对轴承劣化的影响。相比之下，BiLSTM 和 SFAM 模型的预测曲线虽然捕捉到风机运行的某些特性，却未能准确描述劣化的发展趋势。本文所提考虑运行特性影响的预测方法表现出非线性递增趋势，以及增长率随时间不规则变化的特点。这是因为模型考虑了运行工况的时变特点，可以根据不同运行工况实时动态调整预测路径，从而在面对突变或非线性增长时迅速响应。上述结果验证了本文方法的优越性。

3.5　剩余寿命相对误差结果对比

选取 2023 年 12 月 31 日 22:00 作为最后一个时刻开始对未来劣化度发展趋势进行预测，结果见表 2。

表 2 不同方法的 DL 预测准确性分析

Tab. 2 Analysis of prediction accuracy of DL using different methods 单位:h

方法	剩余寿命相对误差
HLCP	640
直接预测的劣化态势感知	17 101
BiLSTM	2 035
SFAM	8 820

由表 2 可知,考虑运行特性影响后预测得到的劣化态势感知结果相对误差仅有 640 h,而直接预测的劣化态势感知结果相对误差高达 17 101 h,相比之下,HLCP 模型的误差减少了 16 461 h。与 BiLSTM 预测方法[11]相比,HLCP 预测模型的误差减少了 1 395 h。与 SFAM 神经网络预测方法[10]相比,误差减少了 8 180 h。由此可见,本文提出的方法具有明显的优越性。

4 结论

(1) 本文构建的动力学劣化态势指标在预测趋势与历史趋势上的相似度约为 74.42%,具有明显的趋势性和单调性。

(2) 所提 HLCP 预测模型通过考虑风机运行特性影响有效提升了劣化趋势预测的精度。实验表明,所提方法的 R^2 达到 0.904,在各项指标上均具有领先优势。

(3) 与其他预测模型相比,所提出的 HLCP 预测模型在预测准确性方面具有显著优势。实验结果显示,所提模型得到的劣化度曲线更符合实际情况,其剩余寿命相对误差仅为 640 h,较其他方法误差更小,提高了预测的可靠性和准确性。

参考文献:

[1] BHARDWAJ U, TEIXEIRA A P, SOARES C G. Reliability prediction of an offshore wind turbine gearbox[J]. Renewable Energy, 2019, 141: 693-706.

[2] NEJAD A R, GUO Yi, GAO Zhen, et al. Development of a 5 MW reference gearbox for offshore wind turbines[J]. Wind Energy, 2016, 19(6): 1089-1106.

[3] 张书瑶, 刘长良, 王梓齐, 等. 基于改进实例学习算法的风电机组齿轮箱状态监测[J]. 动力工程学报, 2024, 44(10): 1620-1631.
ZHANG Shuyao, LIU Changliang, WANG Ziqi, et al. Wind turbine gearbox condition monitoring based on improved instance learning algorithm[J]. Journal of Chinese Society of Power Engineering, 2024, 44(10): 1620-1631.

[4] 范永胜, 丁雪, 邓艾东. 基于深度条件子域自适应网络的轴承跨域故障诊断研究[J]. 动力工程学报, 2024, 44(1): 62-67, 83.
FAN Yongsheng, DING Xue, DENG Aidong. Research on cross-domain fault diagnosis of bearings based on deep conditional subdomain adaptive network[J]. Journal of Chinese Society of Power Engineering, 2024, 44(1): 62-67, 83.

[5] HU Chao, YOUN B D, WANG Pingfeng, et al. Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life[J]. Reliability Engineering & System Safety, 2012, 103: 120-135.

[6] 李俊卿, 耿继亚, 国晓宇, 等. 一种 POA-VMD 和自编码器结合的风电机组轴承劣化指标构建及故障诊断方法[J]. 机床与液压, 2024, 52(13): 219-226.
LI Junqing, GENG Jiya, GUO Xiaoyu, et al. A method for wind turbine bearing deterioration index construction and fault diagnosis by combining POA-VMD and autoencoder[J]. Machine Tool & Hydraulics, 2024, 52(13): 219-226.

[7] LI Lin, MING Tingfeng, LIU Shuyong, et al. An effective health indicator based on two dimensional hidden Markov model[J]. Journal of Mechanical Science and Technology, 2017, 31(4): 1543-1550.

[8] LIU Zhiqi, GUO Yu. A neural network approach for prediction of bearing performance degradation tendency [C]//Proceedings of 2017 9th International Conference on Modelling, Identification and Control. Kunming: IEEE, 2017: 204-208.

[9] ZHANG Shuai, ZHANG Yongxiang, LI Lin, et al. An effective health indicator for rolling elements bearing based on data space occupancy[J]. Structural Health Monitoring, 2018, 17(1): 3-14.

[10] 王海鑫, 刘铭崎, 董鹤楠, 等. 含高比例新能源的电力系统低频振荡分析与抑制综述[J]. 电力自动化设备, 2023, 43(9): 152-163.
WANG Haixin, LIU Mingqi, DONG Henan, et al. Review on analysis and suppression of low-frequency oscillation in power system with high penetration of renewable energy sources[J]. Electric Power Automation Equipment, 2023, 43(9): 152-163.

[11] KUMAR P S, KUMARASWAMIDHAS L A, LAHA S K. Bearing degradation assessment and remaining useful life estimation based on Kullback-Leibler divergence and Gaussian processes regression[J]. Measurement, 2021, 174: 108948.

[12] ALI J B, CHEBEL-MORELLO B, SAIDI L, et al. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network[J].

Mechanical Systems and Signal Processing, 2015, 56-57: 150-172.

[13] WANG Han, TANG Gang, ZHOU Youguang, et al. A novel multiscale deep health indicator with bidirectional LSTM network for bearing performance degradation trend prognosis [J]. Shock and Vibration, 2020, 2020: 8871981.

[14] 王延忠，贾彦蓉，鄂世元. 基于劣化机理的轴承剩余使用寿命预测[J]. 新技术新工艺，2023(5)：77-80.
WANG Yanzhong, JIA Yanrong, E Shiyuan. Prediction of remaining service life of bearing based on deterioration mechanism[J]. New Technology & New Process, 2023(5): 77-80.

[15] 董兴辉，张光，程友星，等. 一种风电机组轴承健康劣化趋势预测方法[J]. 动力工程学报，2018，38(5)：374-379，393.
DONG Xinghui, ZHANG Guang, CHENG Youxing, et al. A method for predicting bearing health degradation trend of wind turbines[J]. Journal of Chinese Society of Power Engineering, 2018, 38(5): 374-379, 393.

[16] GEBRAEEL N, LAWLEY M, LIU R, et al. Residual life predictions from vibration-based degradation signals: a neural network approach[J]. IEEE Transactions on Industrial Electronics, 2004, 51(3): 694-700.

[17] 曲岳晗，赵洪山，程晶煜，等. 基于物联感知数据和张量融合的电力变压器绕组绝缘劣化评估方法[J]. 电工技术学报，2024，39(4)：1208-1220.
QU Yuehan, ZHAO Hongshan, CHENG Jingyu, et al. Evaluation method for power transformer winding insulation degradation based on IoT sensing data and tensor fusion [J]. Transactions of China Electrotechnical Society, 2024, 39(4): 1208-1220.

[18] JIANG Zhiyuan, HUANG Xianzhen, LIU Huizhen, et al. Dynamic reliability analysis of main shaft bearings in wind turbines [J]. International Journal of Mechanical Sciences, 2022, 235: 107721.

[19] KONG Xiannian, TANG Jinyuan, HU Zehua, et al. A new approach for analyzing internal load and fatigue life of deep groove ball bearing in high-speed gearbox system [J]. Journal of Vibration and Control, 2023, 29(21/22): 4972-4986.

[20] YUAN X, ZHU Y S, ZHANG Y Y. Multi-body vibration modelling of ball bearing - rotor system considering single and compound multi-defects[J]. Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics, 2014, 228(2): 199-212.

[21] BELMILOUD D, LACHI M, PRON H, et al. Thermo-dynamical modelisation of the degradation of a ball bearing in variables use conditions[J]. Mechanics & Industry, 2020, 21(6): 608.

[22] 田亮，袁存波. 基于 LSTM 和证据理论的引风机轴承故障诊断[J]. 动力工程学报，2023，43(5)：614-621.
TIAN Liang, YUAN Cunbo. Fault diagnosis of induced draft fan bearing based on LSTM and evidence theory[J]. Journal of Chinese Society of Power Engineering, 2023, 43(5): 614-621.

[23] ZHANG Bin, ZHANG Lijun, XU Jinwu. Degradation feature selection for remaining useful life prediction of rolling element bearings[J]. Quality and Reliability Engineering International, 2016, 32(2): 547-554.