

中文引用格式:葛大龙,丁勇,李登华.基于改进 Prophet-LSTM-PSO 的大坝异常数据检测模型[J].中国安全科学学报,2025,35(8):164-170.

英文引用格式:GE Dalong, DING Yong, LI Denghua. Dam anomaly detection model based on improved Prophet-LSTM-PSO [J]. China Safety Science Journal, 2025, 35(8):164-170.

基于改进 Prophet-LSTM-PSO 的大坝 异常数据检测模型*

葛大龙¹, 丁勇^{**1}副教授, 李登华^{2,3}高级工程师

(1 南京理工大学 安全科学与工程学院, 江苏 南京 210094; 2 南京水利科学研究院,
江苏 南京 210029; 3 水利部水库大坝安全重点实验室, 江苏 南京 210024)

中图分类号:X924.2;TV61

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2025.08.0155

基金项目:国家重点研发计划项目(2024YFC3210703);国家自然科学基金资助(51979174);国家自然科学基金长江水科学研究联合基金资助(U2240221);中央级公益性科研院所基本科研业务费专项资金资助(Y724011)。

【摘要】 为提升大坝监测数据的异常检测性能,提出一种基于改进 Prophet-长短期记忆(LSTM)-粒子群优化(PSO)的大坝异常数据检测模型。首先,通过改进 Prophet 法使得异常数据点位分解得到趋势分量特征;其次,将分解得到的趋势、周期和残差分量映射到三维空间,以三维空间中近邻均值距离数据代替原始时序数据;最后,结合 LSTM 网络与 PSO 算法,设定与优化异常阈值,进而实现异常数据的精准识别。结果表明:相较于传统模型,该模型在检测效果上具有明显提升,且表现出较高的稳定性。在召回率稳定维持在 95% 以上的前提下,精确率与准确率均超过 95%,验证了该方法的有效性与实用性。

【关键词】 Prophet; 长短期记忆(LSTM); 粒子群优化(PSO); 异常数据检测; 大坝监测数据

Dam anomaly detection model based on improved Prophet-LSTM-PSO

GE Dalong¹, DING Yong¹, LI Denghua^{2,3}

(1 School of Safety Science and Engineering, Nanjing University of Science and Technology, Nanjing Jiangsu 210094, China; 2 Nanjing Hydraulic Research Institute, Nanjing Jiangsu 210029, China; 3 Key Laboratory of Reservoir Dam Safety, Nanjing Jiangsu 210024, China)

Abstract: In order to improve the anomaly detection performance of dam monitoring data, a dam abnormal data detection method based on the improved Prophet-long short term memory-particle swarm optimization Prophet-LSTM-PSO was proposed. Firstly, by improving the Prophet method, the trend component features obtained from the decomposition of abnormal data points were clearly visible. Secondly, the decomposed trend, periodic, and residual components were represented in a three-dimensional space, where the original time series data was substituted with the mean distance of the nearest neighbors in this space. Finally, abnormal data points were identified precisely by combining the LSTM network and PSO algorithm to set and optimize anomaly thresholds. The results show that the

* 文章编号:1003-3033(2025)08-0164-07; 收稿日期:2025-03-14; 修稿日期:2025-06-18

** 通信作者:丁勇(1977—),男,江苏海安人,博士,副教授,主要从事大坝结构健康监测方面的研究。E-mail:12005048@njust.edu.cn.

method proposed in this paper significantly improves detection performance and exhibits high stability compared with traditional methods. Notably, while maintaining a stable recall rate exceeding 95%, both accuracy and precision surpass 95%, thereby validating the effectiveness and practicality of the proposed method.

Keywords: Prophet; long short term memory (LSTM); particle swarm optimization (PSO); anomaly data detection; dam monitoring data

0 引言

大坝作为水利工程的主要设施,随着安全监测自动化水平不断提高,监测数据量急剧增长^[1]。随之而来的异常值的数量也在增加,异常值可能为粗差或大坝工作状态的真实反映,若不及时处理,将影响大坝的安全评估^[2]。因此,准确、有效地检测和处理异常值,成为保障大坝安全的重要技术问题^[3]。

异常数据检测方法主要有 4 类,分别是基于统计分析的四分位法、拉伊达准则^[4]等;基于数据多尺度特征分析的小波变换^[5]、经典模态分解^[6]等;基于时空判别的相关性分析法^[7]与聚类方法^[8]等;基于数学模型的随机森林^[9]、支持向量机(Support Vector Machine, SVM)^[10]、长短期记忆(Long Short-Term Memory, LSTM)网络^[11]等。其中,深度学习模型凭借其自适应学习能力,在复杂时序数据的异常检测中表现尤为突出。如张志昂等^[12]考虑到时序数据的不规律性,使用变分自编码器模型作为基础架构,引入时间卷积网络和通道注意力机制,提高检测的准确性。陆旦宏等^[13]提出改进的生成对抗网络-Transformer 模型,以更好地捕捉趋势性特征并加速模型收敛。通过分阶段负荷序列重构帮助模型更好地提取负荷数据异常特征。刘明群等^[14]提出基于 elbow method 和轮廓系数法,为 k 均值聚类算法(k-means Clustering Algorithm, k-means)自动选取聚类数,从而提高了聚类的运行速度与准确率。尽管现有方法在异常检测中取得了一定效果,但仍存在对复杂时序特征适应性不足、参数依赖性强等局限性。

鉴于此,笔者提出一种基于改进 Prophet 分解与 LSTM-粒子群优化(Particle Swarm Optimization, PSO)优化的大坝监测数据异常检测方法,以期有效提升大坝监测数据的异常检测性能。

1 改进 Prophet 分量分解的重构方法

Prophet 模型允许将时间序列数据分解为多个组成部分^[15],每个部分分别捕捉不同的系统性特征,再将这些特征加和起来以完整描述时间序列的

整体行为。Prophet 模型采用这种加和的方式,可将时间序列的变动分解为趋势、周期性变化(季节性)以及其他特殊事件(如节假日)的影响,从而更好地理解 and 预测时间序列数据^[16]。

1.1 改进 Prophet 的分量分解方法

为有效识别大坝监测数据异常点,将趋势分量计算方法修改为计算该点的一阶导数,能更好地反映数据随时间变化的速率;鉴于大坝监测无节假日影响,将 $h(t)$ 项删除。因此,改进后的 Prophet 模型可表示为:

$$y(t) = g(t) + s(t) + \epsilon_t \quad (1)$$

式中: $y(t)$ 为实测时间序列数据; $g(t)$ 为趋势分量,表示该点的数据变化; $s(t)$ 为周期分量; ϵ_t 为剩余残差分量。

其中, $g(t)$ 分量具体计算为:

$$g(t) = \frac{y_t - y_{t-1}}{\Delta t} \quad (2)$$

式中: y_t 为在时间 t 的实测值; y_{t-1} 为在时间 $t-1$ 时的实测值; Δt 为 2 个时间点之间的间隔。在实际应用中,如果时间间隔是固定的(如时间间隔为天),则 Δt 可以简化为 1,此时一阶导数的计算简化为相邻数据点的差分。

$s(t)$ 分量采用周期性模型进行计算,以较好地拟合季节影响,计算公式为:

$$s(t) = \sum_{n=1}^N \left(a_n \cos \frac{2\pi n t}{T} + b_n \sin \frac{2\pi n t}{T} \right) \quad (3)$$

式中: a_n 、 b_n 为傅里叶系数; N 为 Prophet 自调节的傅里叶级数的阶数; T 为时间序列周期长度,年周期为 365.25 d,周周期为 7 d。

ϵ_t 分量为实测值减去趋势分量与周期分量所得:

$$\epsilon_t = y(t) - g(t) - s(t) \quad (4)$$

1.2 基于 Prophet 的三维重构方法

基于 1.1 节中分解得到的基于原始时序数据的趋势、周期、残差 3 分量,以此 3 分量表示 (x_t, y_t, z_t) 坐标,在三维空间中重构,每个时序数据即为三维空间中的一个点位,如图 1a 所示。若在实际数据中出

现异常值,则该点的趋势分量或残差分量会偏离正常分量分布,由此导致在三维空间该点会呈现孤立分布,如图 1b 所示。




图 1 三维重构图

Fig. 1 3D reconstruction diagram

传统方法如果只使用残差分量进行异常识别时^[17],将难以识别小残差大趋势的异常数据。因此,将通过计算各点位到周边 n 个近邻数据的平均距离,以此距离代替该点时序数据。计算公式如下:

$$d_{p_i} = \frac{1}{k} \sum_{j \in N_k(i)} \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (5)$$

式中: d_{p_i} 为点 p_i 到周围 k 个点位的平均距离; (x_i, y_i, z_i) 为点 p_i 的坐标; (x_j, y_j, z_j) 为周边 n 个点位的坐标。

2 基于改进 Prophet-LSTM-PSO 的数据异常检测模型

2.1 LSTM 模型

LSTM 是一种特殊类型的循环神经网络,特别适合处理序列数据^[18]。其结构允许模型不仅考虑当前输入,还能考虑先前的时间步长中的信息。LSTM 模型如图 2 所示。




图 2 LSTM 模型

Fig. 2 LSTM model

2.2 PSO 寻优算法

PSO 算法是一种全局优化方法,通过模拟鸟群或鱼群的群体行为来寻优^[19]。每个粒子代表解空

间中的一个可能解,通过群体中粒子之间的信息交流不断调整自己的位置,确定全局最优解。

F_1 得分作为精确率和召回率的调和平均数,可用于综合考虑模型在分类任务中的精确性和完整性。通过迭代更新粒子的速度和位置来优化 F_1 得分。因此,目标函数设立如下:

$$g(x) = 1 - F_1 \quad (6)$$

通过迭代更新粒子的速度和位置优化 F_1 得分。粒子的速度更新公式为:

$$v_i(t+1) = \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i - x_i(t)) + c_2 \cdot r_2 \cdot (p_g - x_i(t)) \quad (7)$$

式中: ω 为惯性权重; c_1 和 c_2 为加速常数; r_1 和 r_2 为随机数; p_i 为粒子 i 的个人历史最优位置; p_g 为全局最优位置。

粒子位置更新公式为:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (8)$$

2.3 搭建组合模型

将原始的时序数据转换为近邻距离数据后,由于异常数据的趋势或残差分量较大,在三维空间中分布多为孤立,从而其近邻距离数据将普遍偏大。通过提取距离数据,将其输入到 LSTM 模型中,可有效实现异常值阈值设定。

初步检测出的异常值可能包含误报,因此,需要优化异常值阈值,以提高异常数据检测的准确性和可靠性。具体流程为:①通过改进 Prophet 法将原始时序数据分解为 3 分量数据;②将分量数据映射到三维空间,计算各点位到近邻 n 点的平均距离数据代替时序数据(n 值默认取 10);③将距离数据导入 LSTM 模型中进行迭代以及阈值设定;④使用 PSO 寻优算法寻找最优异常值阈值。整体算法流程如图 3 所示。

3 大坝异常数据检测模型试验验证

3.1 数据来源介绍

选取新疆某面板堆石坝作为试验对象,该水库坝高约 110 m,坝顶高程 1 654 m,坝顶长度 352 m,坝底最大宽度约 400 m,年均径流量 34.16 亿 m^3 ,调节库容 7 240 万 m^3 ,总库容 1.25 亿 m^3 。主要水工建筑物包括混凝土面板堆石坝、深孔溢洪道、面孔溢洪道及厂房。选取监测时间范围为 2015 年 1 月 1 日—2018 年 1 月 1 日,监测频率为每日 1 次的测点数据,通过初筛后选取测点见表 1,部分测点数据历史测值如图 4 所示。每支测点数据集为 3 年共




图 3 基于改进 Prophet-LSTM-PSO 的数据异常检测算法流程

Fig. 3 Flowchart of data anomaly detection algorithm based on improved Prophet-LSTM-PSO

1 096 条数据,分为训练集与测试集 2 个部分,其中,2015 年 1 月 1 日—2017 年 12 月 31 日的 731 组数据为训练集,2017 年 1 月 1 日—2018 年 12 月 31 日的 365 组数据为测试集,训练集与测试集比例为 2 : 1。

表 1 测点数据选取

测点类型	监测项目	测点名称
趋势类	使用水平位移计监测坝体水平位移	EX1-1、EX2-3、EX3-7、EX4-4、EX6-2
振荡类	使用钢弦式渗压计监测左岸坝体渗透压力	OH01、OH02、OH07、OH14、OH26
周期类	使用差阻式测缝计监测衬砌混凝土应变	S3-01-2、S3-02-2、S3-04-2、S3-12-1、S3-15-2

3.2 异常数据添加方式

添加异常数量分为小量(1%)、中量(3%)、大量(5%)这 3 种,添加异常位置分为连续添加、孤立添加、混合添加 3 种,添加异常类型分为大数值(超过均值 3 倍标准差)添加、中等数值(超过均值 2 倍标准差)添加、小数值(超过均值 1 倍标准差)添加 3 种,据此共设计 27 组异常添加方式。由 3 种类别共计 15 个测点数据集,以及 27 种异常添加方法,据此可得到 405 支持检测数据集。

3.3 异常监测评价指标

异常监测属于二分类模型,常用的评价指标有:

召回率 R 、准确率 P 、精确率 A 。将经过多类型多水平异常添加的数据标记为正样本,序列中的剩余样本标记为负样本^[20]。具体表达式如下:

$$R = \frac{TP}{TP + FN}$$

$$P = \frac{TP}{TP + FP}$$

$$A = \frac{TP + TN}{TP + TN + FP + FN}$$

式中:TP 为正样本被正确检测的个数;FP 为负样本被误检为正样本的个数;FN 为正样本被误检为负样本的个数;TN 为负样本被正确检测的个数。

3.4 试验结果分析

1) 对照试验设立为 DBSCAN (Density-Based Spatial Clustering of Applications with Noise)、k-means、SVM、高斯混合模型(Gaussian Mixture Model, GMM)、随机森林 5 组,使用文中方法及对照组进行异常检测,按照测点类别、异常数量分类为 9 组。以召回率 R 得分中位数所在试验为该组别最终结果。试验结果见表 2—表 4。

由试验结果可知:随着异常数量的增加,召回率会有小幅度的下降,但基本能维持在 95% 以上,方法稳定性良好。各对照试验中精确率普遍较高,但其召回率极其不稳定。文中方法整体效果较对照试验有明显提升。而在振荡类测点试验中,召回率、准确率均有所下降,可能是振荡类测点难以寻其规律性,阈值寻优不明确所致。

表 2 各类异常添加方式下对比试验的召回率

Table 2 Recall rate of comparative experiments under various abnormal addition methods

检测方法	趋势类添加			振荡类添加			周期类添加		
	大量异常	中量异常	少量异常	大量异常	中量异常	少量异常	大量异常	中量异常	少量异常
LSTM-PSO	0.973	0.965	0.988	0.944	0.959	0.951	0.965	0.957	1
DBSCAN	0.836	0.922	0.954	0.74	0.785	0.864	0.91	0.877	0.896
K-means	0.6	0.558	0.62	0.527	0.512	0.594	0.49	0.534	0.473
SVM	0.96	0.96	0.971	0.928	0.928	0.916	0.984	0.95	0.953
GMM	0.786	0.771	0.871	0.63	0.736	0.852	0.856	0.76	0.799
随机森林	0.916	0.899	0.923	0.817	0.785	0.682	0.932	0.87	0.942

表 3 各类异常添加方式下对比试验的准确率

Table 3 Precision of comparative experiments under various abnormal addition methods

检测方法	趋势类添加			振荡类添加			周期类添加		
	大量异常	中量异常	少量异常	大量异常	中量异常	少量异常	大量异常	中量异常	少量异常
LSTM-PSO	1	0.993	1	0.979	0.974	0.983	0.998	0.998	1
DBSCAN	0.99	0.996	0.996	0.982	0.987	0.991	0.993	0.994	0.993
K-means	0.978	0.98	0.986	0.971	0.978	0.99	0.976	0.981	0.981
SVM	0.941	0.936	0.932	0.95	0.933	0.916	0.942	0.934	0.93
GMM	0.986	0.979	0.989	0.976	0.981	0.982	0.986	0.989	0.983
随机森林	0.994	0.987	0.995	0.981	0.984	0.991	0.995	0.992	0.994

表 4 各类异常添加方式下对比试验的精确率

Table 4 Accuracy of comparative experiments under various abnormal addition methods

检测方法	趋势类添加			振荡类添加			周期类添加		
	大量异常	中量异常	少量异常	大量异常	中量异常	少量异常	大量异常	中量异常	少量异常
LSTM-PSO	0.989	0.996	1	0.97	0.992	0.996	1	1	1
DBSCAN	0.989	0.964	0.86	0.936	0.872	0.712	0.935	0.989	0.899
K-means	0.935	0.919	1	0.944	0.88	0.844	0.942	1	0.924
SVM	0.425	0.374	0.328	0.541	0.363	0.174	0.429	0.365	0.32
GMM	0.905	0.754	0.855	0.957	0.807	0.564	0.863	0.959	0.77
随机森林	0.932	0.805	0.937	0.837	0.817	0.775	0.973	0.894	0.903

2) 消融试验设置 2 组基本组成算法:LSTM 与 PSO,以召回率得分中位数所在试验为该组最终结果。试验结果如图 4 所示。从图 4 可以看出,

LSTM-PSO 算法在保证精确率稳定在 95%的前提下,召回率、准确率均明显领先基本组成算法。即使在振荡类测点试验中,召回率、准确率有小幅下




图 4 消融试验哑铃图

Fig.4 Dumbbell diagram of ablation experiment

降,但较与基本组成算法,稳定性大幅度提升。

4 结 论

1) 通过改进 Prophet 算法,创立一种新型的数据重构模式,使得数据特征表现明显。

2) 结合 LSTM 对复杂数据的特征挖掘能力与 PSO 算法的寻优效果进行异常阈值优化,使得模型对异常数据更加敏感,从而明显提高稳定性与识别效果。

3) 通过多种异常添加方法的效果对比,LSTM-PSO 方法在保持精确率与准确率的同时,召回率仍能基本稳定在 95% 以上。表明基于改进 Prophet-LSTM-PSO 的异常数据检测方法精度较高,能较好地识别出大坝运行状态中的异常数据。

4) 改进 Prophet-LSTM-PSO 的异常数据检测模型仅从数据层面分析,仍然会将一些正常数据识别为异常数据。若从数据的物理监测含义入手,建立约束条件或许可进行深层次的异常识别。

参 考 文 献

- [1] 赵二峰,顾冲时. 混凝土坝长效服役性态健康诊断研究述评[J]. 水力发电学报, 2021, 40(5): 22-34.
ZHAO Erfeng, GU Chongshi. Review on health diagnosis of long-term service behaviors for concrete dams[J]. Journal of Hydroelectric Engineering, 2021, 40(5): 22-34.
- [2] 黄跃文,牛广利,李端有,等. 大坝安全监测智能感知与智慧管理技术研究及应用[J]. 长江科学院院报, 2021, 38(10): 180-185, 198.
HUANG Yuewen, NIU Guangli, LI Duanyou, et al. Research and application of intelligent perception and intelligent management technology for dam safety monitoring[J]. Journal of Yangtze River Scientific Research Institute, 2021, 38(10): 180-185, 198.
- [3] 王建,伍元,郑东健. 基于多传感器信息融合的大坝监测数据分析[J]. 武汉大学学报:工学版, 2004, 37(1): 32-35.
WANG Jian, WU Yuan, ZHENG Dongjian. Analysis of dam safety monitoring data based on multi sensor data fusion theory[J]. Engineering Journal of Wuhan University, 2004, 37(1): 32-35.
- [4] 赵海霞,周少娜,肖化. 四种判别粗大误差准则的比较与讨论[J]. 大学物理实验, 2017, 30(5): 105-108.
ZHAO Haixia, ZHOU Shaona, XIAO Hua. The comparison and discussion of four criterions of gross-error detection[J]. College Physics Experiment, 2017, 30(5): 105-108.
- [5] 尚书宏,曹亮,鲁伟. 基于小波变换特征提取的脱介筛故障诊断算法[J]. 中国安全科学学报, 2023, 33(增 2): 233-237.
SHANG Shuhong, CAO Liang, LU Wei. Fault diagnosis algorithm for medium draining screen based on wavelet transform feature extraction[J]. China Safety Science Journal, 2023, 33(S2): 233-237.
- [6] 杨兴富,刘得潭,杨进,等. 基于 EMD-ABOD 的大坝异常监测数据识别方法研究[J]. 水电能源科学, 2024, 42(6): 162-165.
YANG Xingfu, LIU Detan, YANG Jin, et al. Research on identification method of abnormal monitoring data of dams based on EMD-ABOD[J]. Water Resources and Power, 2024, 42(6): 162-165.
- [7] 赵丽军,邢作霞,刘洋,等. 基于数据分析的风电机组偏航机构异常感知方法研究[J]. 太阳能学报, 2022, 43(1): 108-115.
ZHAO Lijun, XING Zuoxia, LIU Yang, et al. Research on anomaly sensing method of yaw mechanism of wind turbine based on data analysis[J]. Acta Energaie Solaris Sinica, 2022, 43(1): 108-115.
- [8] 李元梦,李登华,丁勇. 基于 DBSCAN 的大坝安全监测异常数据检测算法[J]. 水电能源科学, 2024, 42(1): 149-152.
LI Yuanmeng, LI Denghua, DING Yong. Anomaly data detection algorithm for dam safety monitoring based on DBSCAN[J]. Water Resources and Power, 2024, 42(1): 149-152.
- [9] 李川洲. 基于关联规则和机器学习的大坝监测异常数据自适应识别方法研究[D]. 重庆:重庆交通大学, 2023.
LI Chuanzhou. Research on adaptive identification method for abnormal data of dam monitoring based on association rules and machine learning[D]. Chongqing: Chongqing Jiaotong University, 2023.
- [10] 赵丹,沈志远,刘晓青. 基于 OCISVM 的矿井通风系统在线故障诊断[J]. 中国安全科学学报, 2022, 32(10):

- 76-82.
- ZHAO Dan, SHEN Zhiyuan, LIU Xiaoqing. Online fault diagnosis of mine ventilation system based on OCISVM[J]. China Safety Science Journal, 2022, 32(10): 76-82.
- [11] 熊敏,江德军,高志良,等. 大坝监测数据多维度 LSTM 异常检测与恢复[J]. 电子测量技术, 2023, 46(6): 51-56.
- XIONG Min, JIANG Dejun, GAO Zhiliang, et al. Dam monitoring data multi-dimensional LSTM anomaly detection and recovery[J]. Electronic Measurement Technology, 2023, 46(6): 51-56.
- [12] 张志昂,廖光忠. 改进变分自编码器的工业时序数据异常检测[J]. 计算机工程与设计, 2024, 45(1): 17-23.
- ZHANG Zhi'ang, LIAO Guangzhong. Anomaly detection of industrial time series data based on variational autoencoder[J]. Computer Engineering and Design, 2024, 45(1): 17-23.
- [13] 陆旦宏,范文尧,杨婷,等. 基于生成对抗 Transformer 的电力负荷数据异常检测[J]. 电力工程技术, 2024, 43(1): 157-164.
- LU Danhong, FAN Wenyao, YANG Ting, et al. Anomaly detection of power load data based on Transformer and generative adversarial networks [J]. Electric Power Engineering Technology, 2024, 43(1): 157-164.
- [14] 刘明群,何鑫,覃日升,等. 基于改进 K-means 聚类 k 值选择算法的配网电压数据异常检测[J]. 电力科学与技术学报, 2022, 37(6): 91-99.
- LIU Mingqun, HE Xin, QIN Risheng, et al. Anomaly detection of distribution network voltage data based on improved K-means clustering k-value selection algorithm[J]. Journal of Electric Power Science and Technology, 2022, 37(6): 91-99.
- [15] 孙政杰,丁勇,李登华. 基于 Prophet-GMM 的大坝监测数据异常检测算法[J]. 人民黄河, 2024, 46(3): 132-135,142.
- SUN Zhengjie, DING Yong, LI Denghua. Anomaly detection algorithm of dam monitoring data based on Prophet-GMM[J]. Yellow River, 2024, 46(3): 132-135,142.
- [16] 朱江行,邹晓松,熊炜,等. 基于 Prophet 与 XGBoost 混合模型的短期负荷预测[J]. 现代电力, 2021, 38(3): 325-331.
- ZHU Jianghang, ZOU Xiaosong, XIONG Wei, et al. Short-term power load forecasting based on Prophet and XGBoost mixed model[J]. Modern Electric Power, 2021, 38(3): 325-331.
- [17] 张超,张少飞. 基于 SCADA 温度数据的风电机组发电机驱动端轴承异常识别方法[J]. 轴承, 2022(6): 67-73.
- ZHANG Chao, ZHANG Shaofei. Anomaly recognition method for drive end bearings of wind turbine generator based on SCADA temperature data [J]. Bearing, 2022 (6): 67-73.
- [18] 陈永展,曲建岭,王小飞,等. 时序记忆增强的 CNN-LSTM 滚动轴承故障诊断方法[J]. 噪声与振动控制, 2025, 45(1): 105-111.
- CHEN Yongzhan, QU Jianling, WANG Xiaofei, et al. Rolling bearing fault diagnosis based on CNN-LSTM with time sequential memory enhancement [J]. Noise and Vibration Control, 2025, 45(1): 105-111.
- [19] 郝泽嘉,施玉群,成博超,等. 基于 PSO-LSTM 的大坝变形组合预测模型[J]. 长江科学院院报, 2025, 42(5): 208-214, 222.
- HAO Zejia, SHI Yuqun, CHENG Bochao, et al. A combined PSO-LSTM prediction model for dam deformation[J]. Journal of Changjiang River Scientific Research Institute, 2025, 42(5): 208-214, 222.
- [20] 李松轩,丁勇,李登华. 基于影响因子分解法的大坝监测数据异常检测算法[J]. 人民长江, 2023, 54(4): 234-240.
- LI Songxuan, DING Yong, LI Denghua. Detection method for dam abnormal monitoring data based on influencing factor decomposition [J]. Yangtze River, 2023, 54(4): 234-240.



作者简介: 葛大龙 (2000—)男,河南信阳人,硕士研究生,主要研究方向为大坝结构健康监测。E-mail: cr1026916@foxmail.com。