

基于 FDBO-VMD-FDBO-SVR 的水轮发电机振摆趋势预测方法*

安彪^{1,2}, 于凤荣¹, 钱晶¹, 罗向珑¹, 朱关有³, 杨卫斌⁴, 耿贞伟⁵

(1.昆明理工大学冶金与能源工程学院 昆明,650031)

(2.德宏职业学院医学技术学院 德宏,678400)

(3.华能龙开口水电有限公司 大理,671505)

(4.昆明电机厂有限责任公司 昆明,650100)

(5.云南电网有限责任公司 昆明,650041)

摘要 针对水轮发电机振摆数据的状态趋势预测问题,提出一种结合蜣螂优化算法(dung beetle optimizer,简称 DBO)和支持向量回归(support vector regression,简称 SVR)的振摆趋势预测模型,通过改进的蜣螂优化算法(fortified dung beetle optimizer,简称 FDBO)自动调整变分模态分解(variational mode decomposition,简称 VMD)及 SVR 模型的参数,以提高预测的准确性和效率。首先,通过 FDBO 优化 VMD 参数,改善信号分解的质量;其次,利用优化后的 VMD 分解结果提取信号有效特征;最后,应用 FDBO 优化的 SVR 模型进行趋势预测。实验结果表明:本研究方法在预测精度和收敛速度上显著优于传统方法,尤其在处理非线性和非平稳信号方面表现出色;对于不同方向摆度数据的预测验证,该方法也展现了其在多样化应用场景中的优越性能。此研究为水轮发电机状态预测提供了一种有效方法。

关键词 水轮发电机;深度学习;趋势预测;蜣螂优化算法;变分模态分解

中图分类号 TH17;TV73

0 引言

“十四五”期间,水电是我国可持续能源体系的关键支柱,其高效稳定运行对推动能源现代化转型与环境可持续发展具有重要意义。水电机组的状态趋势预测是保障这一战略顺利实施的重要环节。随着机组向复杂化、集成化和巨型化发展,对其在线状态监测与健康评估提出了更高要求。实现准确的振动趋势预测,不仅能及时识别运行异常,还可有效预防潜在故障、优化维护决策,从而提升机组可靠性与运行效益。振动信号分析是支撑机组运维的核心手段,然而现有预测方法在精确捕捉动态特征、兼顾计算效率与模型泛化能力方面仍面临显著挑战^[1-2]。

在机械与结构系统的状态监测与趋势预测领域,现有方法主要可分为基于物理模型和基于数据驱动两大类。基于物理模型的方法依赖系统机理与先验知识构建数学模型。Lu 等^[3]提出基于扩展工况传递路径分析(operational path analysis extended,

简称 OPAX)的振动环境预测方法,用于精确描述飞机结构及机载设备的振动响应。Qian 等^[4]通过融合相空间扭曲技术与改进裂纹扩展模型,实现了轴承缺陷演化的跟踪与剩余寿命的准确预估。

基于物理模型的预测方法通常依赖复杂机理建模与大量实验数据支撑,在实际应用中存在参数获取困难、模型适应性有限等问题。相比之下,基于数据驱动的预测方法能够直接从运行数据中挖掘系统动态规律,更适用于复杂工业过程的建模与预测。SVR 作为一种典型的数据驱动方法,凭借其在处理小样本、非线性问题方面的出色泛化能力,已成为工程预测领域的重要工具^[5]。

金辉等^[6]结合改进灰狼优化算法(improved grey wolf optimization,简称 IGWO)与 SVR,有效提升了锂电池剩余寿命的预测精度。王钰涵等^[7]分别基于发动机振动时域与频域数据构建 SVR 预测模型,为快速噪声预测提供了有效途径。王瑞等^[8]采用鲸鱼优化算法(whale optimization algorithm,简称

* 国家自然科学基金资助项目(52269020);云南省揭榜挂帅科技资助项目(2202204BW050001)

收稿日期:2024-01-11;修回日期:2024-04-12

WOA)优化SVR参数,实现了高铁沿线超短期风速的高精度预测。这些研究充分体现了SVR在与智能优化算法结合、适应不同工程场景方面的优越性能。

针对复杂的非平稳振动信号,传统时域与频域分析方法往往难以充分挖掘其动态特征,基于时间—频率联合分析的模态分解技术因此成为重要研究方向。职保平等^[9]采用集合经验模态分解(ensemble empirical mode decomposition,简称EEMD)与第2代盲源分离(second-order blind identification,简称SOBI)技术识别水轮机振动源。贾嵘等^[10]结合随机共振与经验模态分解(empirical mode decomposition,简称EMD)进行故障诊断。Kartal等^[11]利用VMD与EEMD预测水力结构冲蚀深度。然而,上述方法多依赖人工参数设置,易出现分解不足或过分解现象,影响特征提取的准确性与稳定性。此外,虽已有研究尝试结合模态分解与机器学习进行趋势预测^[12],但其对数据预处理与特征选择过程较为依赖。付文龙等^[13]提出最优变分模态分解(optimal variational mode decomposition,简称OVMD)与SVR相结合的回归预测模型,仍需要通过大量实验确定最优参数,限制了其实际部署效率。

为提升复杂信号处理的精度与效率,笔者引入FDBO算法,实现对VMD与SVR关键参数的自动优化,以增强模型在非平稳、高噪声环境下的预测能力,为水轮发电机的高效运行和故障预防提供支持。

1 构建预测模型

在构建预测模型的过程中,本研究采用FDBO-VMD-FDBO-SVR复合模型结构。VMD用于高效处理和分解振动信号,通过识别和提取信号的关键模态分量,使后续趋势预测基于更准确的特征信号开展,显著提高了模型对复杂振动信号的分析精度。FDBO提高了参数搜索的效率和模型的收敛速度,也为VMD和SVR参数优化提供了智能化的解决方案,增强了模型对复杂系统动态变化的适应能力,显著提升了模型的泛化能力和预测准确性。通过FDBO算法对SVR参数进行智能调整,模型处理复杂非线性关系的能力得到增强,尤其在小样本数据条件下仍保持较高的预测精度。FDBO的介入不仅优化了SVR的预测精度,也提高了模型对不同振动信号特性的适应性。综上,FDBO-VMD-FDBO-SVR模型克服了单一预测方法在复杂系统状态预测中的局限性,为水轮发电机

故障状态下的振摆预测问题提供了一种有效的解决方案。图1为构建预测模型流程图。




图1 构建预测模型流程图

Fig.1 Flowchart of the predictive model construction process

2 改进蜣螂优化算法

2.1 蜣螂优化算法

DBO是一种受自然界蜣螂行为启发的优化算法。该算法模拟蜣螂在寻找食物时滚动粪球的过程,利用随机搜索策略寻找最优解。蜣螂在不同方向上滚动粪球以探索潜在的食物源,这一过程对应于在解空间中搜索最优点^[14]。算法主要包括初始化、位置更新及偷窃行为等步骤,其中,位置更新是核心环节,涉及蜣螂根据环境信息调整其路径。尽管DBO算法在多个领域展现出了有效性,但在处理一些复杂问题时仍存在收敛速度较慢和易陷入局部最优解的问题,这些限制凸显了进一步改进的必要性。

2.2 改进蜣螂优化算法的实现

FDBO算法通过引入Singer混沌映射、可变螺旋搜索策略及Levy随机飞行策略,有效提升了算法性能和全局搜索能力,同时显著提高了收敛速度和逃离局部最优解的能力,使FDBO在处理复杂优化问题时表现更加优异。该算法的改进策略如下。

1) 采用新型Singer混沌映射方法,提高算法的全局搜索性能。该映射策略不仅使初始种群分布更加均匀,还增加了种群多样性,有助于算法有效跳出局部最优解。

新型Singer混沌映射方法的表达式为

$$x_{k+1} = u(7.86x_k - 23.31x_k^2 + 28.75x_k^3 - 13.302875x_k^4) \quad (1)$$

$$u \in (0.9, 1.08)$$

2) 引入自适应的可变螺旋搜索策略。该策略能够在搜索过程中更灵活地选择不同的探索半径,使繁殖位置与小蛱螂觅食均以螺旋形式在空间中搜索,扩展了发现者探索未知区域的能力,有助于算法跳出局部最优,从而提高全局搜索能力。

蛱螂繁殖原公式为

$$B_i^{t+1} = x_{gbest}^t + b_1(B_i^t - Lb^*) + b_2(B_i^t - Ub^*) \quad (2)$$

改进后的蛱螂繁殖公式为

$$B_i^{t+1} = x_{gbest}^t + e^{z^t} \cos(2\pi l) b_1(B_i^t - Lb^*) + e^{z^t} \cos(2\pi l) b_2(B_i^t - Ub^*) \quad (3)$$

小蛱螂觅食原公式为

$$x_i^{t+1} = x_i^t + C_1(x_i^t - Lb^t) + C_2(x_i^t - Ub^t) \quad (4)$$

改进后的小蛱螂觅食公式为

$$x_i^{t+1} = e^{z^t} \cos(2\pi l) x_i^t + C_1(x_i^t - Lb^t) + C_2(x_i^t - Ub^t) \quad (5)$$

3) 引入自适应的可变螺旋搜索策略。该策略通过在搜索过程中调整探索半径,扩大了算法的搜索范围,有助于有效逃离局部最优解,增强全局搜索能力。

蛱螂偷窃原公式为

$$x_i^{t+1} = x_{lbest}^t + Sg(|x_i^t - x_{gbest}^t| + |x_i^t - x_{lbest}^t|) \quad (6)$$

改进后的蛱螂偷窃公式为

$$x_i^{t+1} = \text{levy}x_{lbest}^t + Sg(|x_i^t - x_{gbest}^t| + |x_i^t - wx_{lbest}^t|) \quad (7)$$

图2为改进蛱螂优化算法流程图。




图2 改进蛱螂优化算法流程图

Fig.2 Flowchart of the improved FDBO

本研究通过3个经典测试函数(单峰、多峰、固定多峰)验证FDBO的搜索性能。其中:单峰函数(F_1)用于测试局部搜索能力;多峰函数(F_{11})和固定多峰函数(F_{16})用于评估全局搜索能力。将FDBO与5种优化算法进行性能比较,分别为:灰狼优化算法(grey wolf optimizer,简称GWO)、麻雀搜索算法(sparrow search algorithm,简称SSA)、鲸鱼优化算法(whale optimization algorithm,简称WOA)、北方苍鹰算法(northern goshawk optimizer,简称NGO)以及原始DBO算法。各算法在测试函数上的寻优对比如图3所示。可以看出,改进后的算法在搜索精度以及收敛速度上皆优于其他算法,其性能得到了显著提高。




图3 各算法在测试函数上的寻优对比

Fig.3 Comparison of optimization performance of different algorithms on test functions

3 变分模态分解的优化

3.1 变分模态分解

由于EMD存在端点效应和模态混叠等局限性^[15],为此笔者引入了VMD,其通过将复杂信号分

解为一系列固有模态函数(intrinsic mode functions, 简称IMFs),可有效处理非线性和非平稳信号,然而,其传统参数设置依赖人工经验。本研究通过FDBO自动调整VMD参数,克服了传统方法的局限,提升了分解质量与效率,增强了模型在复杂信号分析中的适用能力。

3.2 FDBO优化VMD

VMD通过将复杂信号分解为多个IMFs来降低信号复杂度,提高处理效率。为了优化VMD算法,本研究建立了适应度函数并引入评价指标来衡量IMF的性能。通过上述优化措施,VMD算法能更准确地处理水电机组信号,提高分析精度和效率。具体评价指标建立过程如下。

1) 样本熵:用于量化数据的规律性,尤其反映信号的稀疏性。样本熵越高,信号的不确定性越大。

2) 皮尔逊(Pearson)相关系数:用于评估重构信号与原始信号之间的相似度。

3) VMD参数优化:本研究采用FDBO算法,综合样本熵与皮尔逊相关系数对VMD参数进行优化,以全面提高分解性能。

将VMD的参数组合 $[K, \alpha]$ 作为蜣螂种群的位置,构建适应度函数进行优化,即

$$f_{\text{FDBO}} = \min \left[\frac{\text{sampEn}(\text{data}, q, r)}{p^*} \lg(\omega) \right] \quad (8)$$

其中: $\lg(\omega)$ 为相对聚合代数项; $\text{sampEn}(\cdot)$ 为样本熵函数; data 为随机信号时间序列; q 为嵌入维度; r 为相似性容限; p^* 为皮尔逊相关系数。

4) 采用FDBO对VMD中的模态数 K 和惩罚系数 α 进行筛选与优化。图4为FDBO优化VMD流程图。




图4 FDBO优化VMD流程图

Fig.4 Flowchart of FDBO optimization for VMD

4 支持向量回归的优化

4.1 支持向量回归

SVR是一种基于统计学习的有效回归预测方法,其关键在于合理选择核函数参数与惩罚系数,以达到最佳预测效果。然而,传统的参数选择方法会导致效率低下、模型过拟合或欠拟合^[16]。为解决上述问题,本研究采用FDBO算法优化SVR参数,以提高模型的泛化能力和预测精度。通过智能优化策略,FDBO算法能够自动调整核函数半径与惩罚系数,有效改善SVR模型在处理复杂数据时的性能。

4.2 FDBO优化SVR

SVR的性能高度依赖于核函数参数 g 和惩罚系数 c ,FDBO算法通过智能化的方法自动调整这些关键参数。图5为FDBO优化SVR流程图。该流程的目标是运用智能算法找到最优的SVR参数,从而实现高效、准确的模型性能。




图5 FDBO优化SVR流程图

Fig.5 Flowchart of FDBO optimization for SVR

5 实验验证

5.1 实验数据获取

以国内某水电站为例进行验证实验。该水电站安装5台350 MW的混流式水轮发电机组,年发电量近70亿度。水轮机额定水头为70 m,额定出力为379.2 MW,额定流量为600.5 m³/s。选取该电站水轮发电机在正常运行状态下的398组上导轴承 x 方向摆度监测数据进行趋势预测分析。取前318组数

据作为训练样本,后 80 组数据作为测试样本。图 6 为水电机组振摆位置示意图。




图 6 水电机组振摆位置示意图
Fig.6 Hydroelectric unit swing position schematic

5.2 实验数据处理

由于水力机组复杂的工作环境和振动数据的非线性特征,使得原始数据常含误差,因此本研究采用 FDBO-VMD 方法,从原始数据中提取更精确可靠的信号。此方法确保了数据质量,提高了分析准确性和模型预测能力。

设置 FDBO-VMD 参数种群数为 20,最大迭代次数为 10, α 的搜索范围为[500,3 000], K 的搜索范围为[2,15]。经优化寻优,全局最佳适应度函数值 $f_{\text{FDBO}}=0.085\ 35$,对应的 VMD 最佳参数组合为[12,2 967]。

5.3 实验数据预测

采用 FDBO-VMD 对数据进行相空间重构,并建立 SVR 模型进行预测分析。为验证所提模型的有效性,选取 SVR、VMD-SVR、VMD-FDBO-SVR 及 FDBO-VMD-FDBO-SVR 预测模型进行对比分析。其中:SVR 模型直接对原始振动序列进行相空间重构并进行回归预测;VMD-SVR 模型基于 VMD 对原始振动序列进行信号分解,对各子序列分别进行相空间重构和回归预测,并对所有预测结果求和,得到最终的振动预测值。根据经验,VMD 的参数设置为 $K=7,\alpha=1\ 000$ 。

各模型对上导轴承 x 向摆度的预测结果如图 7 所示。可以看出:直接使用 SVR 模型进行预测的效

果最差;经过 VMD 分解后再用 SVR 模型预测,效果有所改善,但仍有提升空间;经 VMD 分解并应用 FDBO 算法对 SVR 模型进行参数优化后,预测效果显著提高,表现出更好的性能;最佳的预测效果出现在采用 FDBO 算法同时优化 VMD 和 SVR 模型参数时,该方法在所有模型中均表现出最佳性能。




图 7 各模型对上导轴承 x 向摆度的预测结果
Fig.7 Predicted results of upper guide bearing x -direction swing for hydropower unit

为了全面评估不同模型的预测效果,本研究采用 4 个主要统计指标:均方根误差(root mean square error,简称 RMSE)、平均绝对误差(mean absolute error,简称 MAE)、平均绝对百分比误差(mean absolute percentage error,简称 MAPE)和决定系数 R^2 。其中:RMSE 反映预测值与实际值的平均误差大小;MAE 表示误差的平均水平;MAPE 以百分比形式显示预测误差的相对大小;决定系数 R^2 衡量模型的拟合程度。

各模型振摆数据预测性能对比如表 1 所示。可以看出,FDBO-VMD-FDBO-SVR 预测模型的各项评价指标均优于其他预测模型,证明了 FDBO 算法在优化 VMD 和 SVR 模型参数方面具有重要作用,并表明通过多重组合优化可以显著提高振摆数据的预测性能。

表 1 各模型振摆数据预测性能对比
Tab.1 Comparative performance of various models in swing data prediction

模型	RMSE/ μm	MAE/ μm	MAPE/ %	R^2
SVR	6.992 9	5.597 5	3.005 6	—0.294 50
VMD-SVR	2.769 7	2.177 9	1.156 2	0.796 92
VMD-FDBO-SVR	1.869 8	1.427 7	0.766 5	0.907 45
FDBO-VMD-FDBO-SVR	1.595 8	1.255 7	0.671 75	0.932 58

5.4 实验验证

除了上导轴承 x 向摆度数据外,实验验证还包

括水轮发电机正常运行条件下的上导轴承 y 向摆度数据,以及上机架水平 x 向和 y 向振动数据。这些数据用于验证模型在预测不同方向摆度变化时的有效性和准确性。

图8为上导轴承 y 向摆度预测结果。图9为上机架水平 y 向预测结果。图10为上机架水平 x 向预测结果。表2为不同方向振动预测的模型性能评估。笔者使用2种方法评价模型效果:①通过图8~10的直观比较;②使用如表2所示的评价指标。

图8~10表明,无论是上导轴承 y 向摆度,还是上机架水平 x 向或 y 向振动数据,预测模型均显示出与上导轴承 x 向摆度数据相似的预测准确度。这证明了模型在处理不同方向摆度数据时的一致性和有效性。

从表2可以看出,模型在所有测试数据集上的




图8 上导轴承 y 向摆度预测结果
Fig.8 Predicted results of upper guide bearing y -direction swing for hydropower unit

RMSE、MAE、MAPE和决定系数均显示出了优异性能,验证了模型预测的准确性和可靠性。可见,该模型不仅适用于单一方向的摆度数据,还能够精确预测多方向的振动数据,显示出其优越的适用性和全面性。




图9 上机架水平 y 向预测结果
Fig.9 Predictive results for horizontal y -direction swing of upper bracket




图10 上机架水平 x 向预测结果
Fig.10 Predictive results for horizontal x -direction swing of upper bracket

表2 不同方向振动预测的模型性能评估

Tab.2 Model performance evaluation for vibration prediction in different directions

模型	RMSE/ μm			MAE/ μm			MAPE/%			R^2		
	上导轴	上机架	上机架	上导轴	上机架	上机架	上导轴	上机架	上机架	上导轴	上机架	上机架
	承 y 向	水平 x	水平 y	承 y 向	水平 x	水平 y	承 y 向	水平 x	水平 y	上导轴承 y 向摆度	水平 x 向	水平 y 向
	摆度	向振动	向振动	摆度	向振动	向振动	摆度	向振动	向振动		振动	振动
SVR	5.193 0	8.570 9	7.963 3	4.218 1	7.022 8	6.461 3	2.236 4	6.109 8	5.990 6	0.250 51	0.157 45	0.069 90
VMD-SVR	3.294 4	3.366 3	3.459 7	2.753 0	2.619 4	2.699 8	1.442 0	2.326 6	2.537 4	0.496 72	0.821 46	0.798 05
VMD-FDBO-SVR	1.465 7	2.285 7	2.649 3	1.162 5	1.799 9	2.037 5	0.611 9	1.575 3	1.896 3	0.900 38	0.917 68	0.881 58
FDBO-VMD-FDBO-SVR	1.106 7	1.606 5	1.601 2	0.864 9	1.236 2	1.303 6	0.454 4	1.082 9	1.210 9	0.943 21	0.959 34	0.956 75

为进一步验证所提出模型的有效性,采用水轮发电机正常运行条件下的上导轴承 x 向摆度数据以及上机架水平 x 向振动数据作为验证数据,并选择以下2种模型进行比较:①结合VMD进行信号特征提取,并采用遗传算法(genetic algorithm,简称GA)来优化反向传播(back propagation,简称BP)神经网络

参数的VMD-GA-BP模型;②整合了WOA、VMD以及时序卷积网络(temporal convolutional network,简称TCN)的WOA-VMD-TCN模型。不同模型的性能评估指标对比如表3所示。正常运行状态下与报警状态下模型性能对比分别如图11、12所示。




图 11 正常运行状态下模型性能对比

Fig.11 Model performance comparison under normal operating conditions

可见,在水轮发电机正常运行状态下,所提出的预测模型展现出更优的性能。具体而言,该模型的预测曲线与真实值曲线高度吻合,预测结果更接近实际运行数据,波动趋势与实际情况的同步性较好,各项评价指标均优于其他对比模型,反映出该模型能够更准确地捕捉水轮发电机振动数据的关键特征。

在水轮发电机故障情况下,通过实验结果可以看出,所提出的预测模型仍能保持较高的预测准确性,而其余 2 个模型的预测精度明显下降。这表明




图 12 报警状态下模型性能对比

Fig.12 Model performance comparison under alarm conditions

在处理复杂且可能存在非线性和非平稳特征的振动信号时,所提出模型具有更强的鲁棒性和适应性。

与 VMD-GA-BP 模型和 WOA-VMD-TCN 模型相比,所提出的模型成功预测了一级和二级报警状态下的故障可能性和严重性,表现出更高的预测准确性和鲁棒性。这不仅验证了所提模型在常规设备监测以及异常情况下的故障预警能力,也凸显了其在实际工业应用中的实用性和可靠性,为未来在更广泛应用场景中提升模型性能提供了理论支持。

表 3 不同模型的性能评估指标对比

Tab.3 Comparative performance metrics of predictive models

模型	RMSE/ μm		MAE/ μm		MAPE/%		R^2	
	上导轴承	上机架水平	上导轴承	上机架水平	上导轴承	上机架水平	上导轴承	上机架水平
	x 向摆度	x 向振动	x 向摆度	x 向振动	x 向摆度	x 向振动	x 向摆度	x 向振动
VMD-GA-BP	2.098 4	2.951 0	1.690 4	2.329 2	0.907 1	2.028 2	0.883 44	0.862 79
WOA-VMD-TCN	3.148 5	5.122 4	2.564 6	4.221 4	1.366 7	3.635 6	0.737 58	0.586 57
FDBO-VMD-FDBO-SVR	1.543 4	1.632 5	1.233 7	1.215 2	0.661 3	1.033 4	0.923 57	0.961 14

6 结束语

针对水轮发电机振摆数据的故障预测问题,笔者开发了一种基于 FDBO 算法与 SVR 的复杂系统状态预测模型。通过自动调整 VMD 和 SVR 参数,该模型不仅能在正常运行条件下有效预测水轮发电机的工作状态,还能准确预测报警状态下的故障风险。通过与 VMD-GA-BP 模型和 WOA-VMD-TCN 模型的比较,本模型在正常运行及报警状态下也展现出了更高的预测准确性和鲁棒性,有效提升了故障预测的精度和效率。然而,在某些极端条件下的预测准确性和模型的泛化能力仍有待进一步探究。本

研究方法在理论上为水电机组状态监测与故障预测提供了新的视角,在实际应用中也展现出一定潜力。

参 考 文 献

[1] YAN S K, CHEN F, YANG J D, et al. A multistep prediction model for the vibration trends of hydroelectric generator units based on variational mode decomposition and stochastic configuration networks[J]. Sensors, 2023, 23(24): 9762.

[2] 罗毅, 武博翔. 基于深度学习 LSTM-DBN 的水轮机振动故障预测方法[J]. 振动、测试与诊断, 2022, 42(6): 1233-1238.

- LUO Yi, WU Boxiang. Vibration fault prediction method of hydraulic turbine system based on deep learning LSTM-DBN[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(6): 1233-1238. (in Chinese)
- [3] LU H, WANG J D, LIAN Y D, et al. Random vibration fatigue behavior of directionally solidified superalloy: experiments and evaluation of life prediction methods [J]. International Journal of Fatigue, 2023, 175: 107746.
- [4] QIAN Y N, YAN R Q, GAO R X. A multi-time scale approach to remaining useful life prediction in rolling bearing[J]. Mechanical Systems and Signal Processing, 2017, 83: 549-567.
- [5] AÇIKKAR M, ALTUNKOL Y. A novel hybrid PSO and GS-based hyperparameter optimization algorithm for support vector regression[J]. Neural Computing and Applications, 2023, 35(27): 19961-19977.
- [6] 金辉, 胡寅逍, 葛红娟, 等. 基于改进 GWO-SVR 算法的锂电池剩余寿命预测[J]. 工程科学学报, 2024, 46(3): 514-524.
- JIN Hui, HU Yinxiao, GE Hongjuan, et al. Remaining useful life prediction for lithium-ion batteries based on an improved GWO-SVR algorithm[J]. Chinese Journal of Engineering, 2024, 46(3): 514-524. (in Chinese)
- [7] 王钰涵, 郑旭, 周南, 等. 基于振动测试和机器学习的发动机噪声预测[J]. 振动、测试与诊断, 2025, 45(3): 506-512.
- WANG Yuhan, ZHENG Xu, ZHOU Nan, et al. Research on engine radiated noise prediction based on vibration test and machine learning[J]. Journal of Vibration, Measurement and Diagnosis, 2025, 45(3): 506-512. (in Chinese)
- [8] 王瑞, 马祯, 李磊. 基于 CEEMDAN-WOA-SVR 的高铁沿线超短期风速预测方法[J]. 中国铁道科学, 2023, 44(6): 80-86.
- WANG Rui, MA Zhen, LI Lei. Prediction method of ultra-short-term wind speed along high speed railway based on CEEMDAN-WOA-SVR[J]. China Railway Science, 2023, 44(6): 80-86. (in Chinese)
- [9] 职保平, 秦净净, 杨春景, 等. 基于 EEMD-SOBI 的水电机组多源信息分离处理[J]. 振动与冲击, 2023, 42(4): 229-235.
- ZHI Baoping, QIN Jingjing, YANG Chunjing, et al. Multi-source information separation of a hydroelectric generating set based on EEMD-SOBI[J]. Journal of Vibration and Shock, 2023, 42(4): 229-235. (in Chinese)
- [10] 贾嵘, 李涛涛, 夏洲, 等. 基于随机共振和经验模态分解的水力发电机组振动故障诊断[J]. 水利学报, 2017, 48(3): 334-340.
- JIA Rong, LI Taotao, XIA Zhou, et al. Vibration fault diagnosis of hydroelectric generating unit by using stochastic resonance and empirical mode decomposition [J]. Journal of Hydraulic Engineering, 2017, 48(3): 334-340. (in Chinese)
- [11] KARTAL V, EMIROGLU M E, KATIPOGLU O M, et al. Prediction of scour hole characteristics caused by water jets using metaheuristic artificial bee colony-optimized neural network and pre-processing techniques [J]. Journal of Hydroinformatics, 2023, 25(6): 2427-2443.
- [12] 毕扬, 郑波, 张亚武, 等. 基于 MIC 与 BiGRU 的水电机组振动趋势预测[J]. 水利学报, 2021, 52(5): 612-621.
- BI Yang, ZHENG Bo, ZHANG Yawu, et al. Vibration trend prediction of hydroelectric generating unit based on MIC and BiGRU[J]. Journal of Hydraulic Engineering, 2021, 52(5): 612-621. (in Chinese)
- [13] 付文龙, 周建中, 张勇传, 等. 基于 OVMD 与 SVR 的水电机组振动趋势预测[J]. 振动与冲击, 2016, 35(8): 36-40.
- FU Wenlong, ZHOU Jianzhong, ZHANG Yongchuan, et al. Vibration trend prediction of hydroelectric generating unit based on OVMD and SVR[J]. Journal of Vibration and Shock, 2016, 35(8): 36-40. (in Chinese)
- [14] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [15] BISOI R, DASH P K, PARIDA A K. Hybrid variational mode decomposition and evolutionary robust kernel extreme learning machine for stock price and movement prediction on daily basis [J]. Applied Soft Computing, 2019, 74: 652-678.
- [16] AI R B, LI C, LI N. Application of an optimized support vector regression algorithm in short-term traffic flow prediction [J]. Journal of Information Processing Systems, 2022, 18(6): 719-728.



第一作者简介:安彪,男,1999年12月生,硕士。主要研究方向为水电机组故障诊断及趋势预测、算法优化。
E-mail:827003782@qq.com

通信作者简介:于凤荣,女,1971年3月生,博士、副教授、硕士生导师。主要研究方向为流体机械稳定控制、性能优化及数值模拟。
E-mail:yufengrong@kust.edu.cn