

基于二次模态分解和深度学习的大坝变形预测模型

刘相杰, 刘小生, 张龙威

(江西理工大学土木与测绘工程学院, 江西 赣州 341000)

摘要: 为充分提取大坝变形监测数据的非线性和非平稳性特征, 深度挖掘其前后信息的拓扑关系, 有效提高预测精度, 提出了一种基于二次模态分解和蜣螂优化算法的双向长短期记忆神经网络大坝变形预测模型。该模型引入融合自适应噪声完备集成经验模态分解和变分模态分解的二次模态分解对数据进行预处理, 有效降低高频非平稳性分量对预测精度的不利影响, 并利用蜣螂优化算法对双向长短期记忆神经网络进行超参数寻优以深度挖掘大坝变形数据的有效信息。以某水电站大坝为例, 将该模型预测结果与多种常用模型的预测结果进行对比分析, 结果表明该模型可有效挖掘大坝变形数据复杂的非线性特征, 其预测精度明显优于对比模型, 验证了该模型在大坝变形预测中的可行性与优越性。

关键词: 大坝变形预测; 二次模态分解; 蜣螂优化算法; 双向长短期记忆神经网络

中图分类号: TV698.1

文献标志码: A

文章编号: 1006-7647(2024)03-0101-06

Dam deformation prediction model based on quadratic modal decomposition and deep learning//LIU Xiangjie, LIU Xiaosheng, ZHANG Longwei (School of Civil and Surveying Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: In order to fully extract the nonlinear and non-stationary characteristics of the dam deformation monitoring data, deeply mine the topological relationship between the preceding and following information, effectively improve the prediction accuracy, a bidirectional long short-term memory (LSTM) neural network dam deformation prediction model based on quadratic modal decomposition and dung beetle optimization algorithm is proposed. The model introduces a quadratic modal decomposition that combines adaptive noise-complete integrated empirical modal decomposition and variational modal decomposition to preprocess the data, which effectively reduces the negative influence of high-frequency non-stationary components on the prediction accuracy, and utilizes dung-beetle optimization algorithm to search for the optimal hyper-parameters of bidirectional LSTM neural networks to deeply explore the effective information of the deformation data of the dams. Taking a hydropower dam as an example, the prediction results of the model are compared with those of several commonly used models, and the experimental results show that the model can effectively exploit the complex nonlinear features of dam deformation data, and its prediction accuracy is significantly better than its counterparts, and the feasibility and superiority of the model in the prediction of dam deformation is verified.

Key words: dam deformation prediction; secondary modal decomposition; dung beetle optimization algorithm; bidirectional LSTM neural network

大坝作为我国重要的水利设施,其安全性备受社会各界关注。受大坝自身地质条件、施工质量以及年久老化等多种因素影响^[1],大坝易产生变形位移,一旦溃决将产生无可估量的经济损失和人口伤亡。因此,通过建立有效且高精度的大坝变形预测模型,对大坝变形趋势进行准确预测具有重要意义^[2]。

目前,传统的大坝变形预测方法主要有确定性模型、统计模型和混合模型,这些模型结构简单、计算高效,但在非线性特征分析处理上表现不佳,难以充分挖掘并学习大坝变形数据之间复杂的非线性关系。随着深度学习的快速发展,其在数据特征挖掘分析上表现出不错的效果,基于深度学习的模型也开始在大坝变形预测领域中得到了应用。郭张军

基金项目: 国家自然科学基金项目(42171437)

作者简介: 刘相杰(1999—),男,硕士研究生,主要从事变形监测与预报研究。E-mail:1729619452@qq.com

通信作者: 刘小生(1963—),男,教授,博士,主要从事大地测量学与测绘工程研究。E-mail:lx9103@163.com

等^[3]引入长短期记忆(long short-term memory, LSTM)神经网络建立基于深度学习的大坝变形预测模型,实现较高精度的变形预测,但忽略了预测误差序列的影响。胡安玉等^[4]提出一种 LSTM 与自回归差分移动平均模型(autoregressive integrated moving average model, ARIMA)相结合的大坝变形预测模型,提高了模型拟合度和预测精度,但面对噪声较多、非平稳性较强的数据时,预测精度有限。

为进一步提高预测精度,将擅长于处理非线性和非平稳性数据的模态分解技术与深度学习方法合理结合进行预测成为新的趋势。宋洋等^[5]针对变形数据序列的非平稳性特征,引入自适应噪声完备集成经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)和排列熵(permutation entropy, PE)进行大坝变形数据平稳化处理,并与 LSTM 相结合,建立了组合的大坝变形预测模型,更好地挖掘了大坝变形数据的非线性和非平稳性特征,提高了预测精度,但忽略了 CEEMDAN 分解后的高频分量对预测结果的影响。董泳等^[6]提出一种结合经验模态分解(empirical mode decomposition, EMD)、集合经验模态分解(ensemble empirical mode decomposition, EEMD)和 LSTM 的大坝变形预测模型,采用 EEMD 对 EMD 分解后的高频分量再次分解,有效降低了高频分量的强非平稳性,深度挖掘了有效信息,但忽略了 EMD 中的模态混叠问题,导致分解得到的分量可能不精确。陈竹安等^[7]提出一种结合变分模态分解(variational mode decomposition, VMD)和 LSTM 的大坝变形预测模型,有效避免了模态混叠问题,提升了“分解-预测-重构”模型的预测性能,但忽略了 LSTM 超参数的寻优,影响了最后的预测精度。张明岳等^[8]建立了基于 VMD 和双向长短期记忆神经网络(bidirectional long short-term memory, BiLSTM)的滑坡位移预测模型,考虑前向和后向两个方向上的滑坡位移序列信息,更深入地挖掘原始数据所包含的信息,预测精度得到有效提高,但忽略了模型训练收敛时间较长的问题。

基于此,针对上述模型存在的有效信息挖掘不充分、预测精度不高和训练收敛时间较长等问题,本文采用 CEEMDAN 和 VMD 相结合的二次模态分解方法,并与蜣螂优化算法(dung beetle optimizer, DBO)的 BiLSTM 有机融合,建立了基于二次模态分解-DBO-BiLSTM 的大坝变形组合预测模型,并将该模型应用到某水电站大坝变形预测中,以验证该模型的可行性。

1 基本原理与方法

1.1 二次模态分解

大坝变形原始数据受到气温、时间效应、施工方法等多种因素的影响,具有不规则波动性和高非线性等特征,导致直接预测的精度较低。本文采用二次模态分解对大坝变形原始数据进行分解,以提高大坝变形预测的准确性和稳定性。首先使用 CEEMDAN 将大坝变形原始数据分解成一系列分量,从而提取大坝变形原始数据中的不同特征信息,降低其复杂性和非平稳性;其次使用 VMD 对频率最高、相关系数最小的分量(IMF1)进行二次模态分解,降低高频分量复杂性,提高原始数据的表征能力,从而进一步提高预测精度。

CEEMDAN 算法^[9]是建立在 EMD 和 EEMD 基础上的一种改进信号处理方法,主要通过原始信号上添加自适应高斯白噪声,并通过多次迭代分解和噪声叠加过程,获得更完备的分解结果,更好地捕捉信号的特征,以有效避免 EMD 的模态混叠现象和 EEMD 引入白噪声的问题,同时可以消除虚假信息干扰,提高分解的准确性和稳定性,适用于非线性和非平稳信号的分解和分析。

VMD 算法^[10]是常用于处理非线性信号的一种方法,不同于 EMD、CEEMDAN 等算法,该算法可以将复杂的数据分解成一组具有不同频率和幅度的分量,实现各分量从低频到高频的有效分离,从而更准确地捕捉大坝变形数据的局部特征,降低其非线性和非平稳性对预测结果的影响^[11],适用于信号的时频局部化分解和分析。

1.2 BiLSTM 模型

LSTM^[11]的提出有效解决了循环神经网络(recurrent neural network, RNN)存在的梯度消失和爆炸问题,能够更好地处理数据长期依赖关系。但其只能单向地处理时间序列,无法同时编码前向和后向的信息,未能充分捕捉到序列数据中前后向的关联性。而在时序预测中,同时考虑原始序列数据的前后向信息可以提升预测精度^[12]。为了解决该问题,Graves 等^[13]在 2005 年提出了 BiLSTM, BiLSTM 由两个独立的 LSTM 层组成,正向 LSTM 层按照时间的正向顺序处理输入序列,而反向 LSTM 层则按照时间的反向顺序处理输入序列。通过将正向和反向 LSTM 的输出进行连接, BiLSTM 能够综合利用前向和后向两个方向上的输入序列信息,从而更深入地挖掘原始数据所包含的信息。这样的设计使得 BiLSTM 在对序列数据进行全面分析时展现出优越性,特别是在大坝变形等复杂时序预测问题上,

BiLSTM 模型往往能提供比单向 LSTM 更为精确的预测结果^[14]。

1.3 DBO 算法

网络模型超参数的选择决定了模型的预测性能。当采用 BiLSTM 模型进行大坝变形预测时,其超参数的选择显著影响了模型预测精度和收敛速度,为避免手动调参带来的预测精度下降、耗时增加等问题,本文引入 DBO 对 BiLSTM 模型进行参数寻优。DBO 算法是由 Xue 等^[15]提出的一种智能优化算法,通过模拟蜣螂的滚球、跳舞、觅食、偷窃和繁殖行为进行寻优。本文将蜣螂个体作为优化策略,蜣螂位置维数作为 BiLSTM 模型待优化参数数量,均方根误差作为适应度函数,通过不断迭代的蜣螂位置更新,来获得 BiLSTM 模型的最优超参数组合。该算法具有收敛性好、搜索策略动态更新以及寻优能力强的优点。同时,在准确性和有效性方面,DBO 算法表现出比传统智能算法更精确的优势。

2 模型构建

2.1 模型输入变量

本文以引起大坝发生变形位移的影响因素作为模型的输入变量,影响因素主要有水压、温度和时效影响因子。输入变量共 10 项,分别为温度因子 $\sin(2\pi t/365) - \sin(2\pi t_0/365)$ 、 $\sin(4\pi t/365) - \sin(4\pi t_0/365)$ 、 $\cos(2\pi t/365) - \cos(2\pi t_0/365)$ 、 $\cos(4\pi t/365) - \cos(4\pi t_0/365)$, 水压因子 $h - h_0$ 、 $h^2 - h_0^2$ 、 $h^3 - h_0^3$ 、 $h^4 - h_0^4$, 时效因子 $\theta - \theta_0$ 、 $\ln \theta - \ln \theta_0$, 其中 t 为当前观测距起始观测的累计天数; t_0 为建模初始日至始测日的累计天数; h 为当前水位; h_0 为起测日的水位; θ 为 $0.01t$; θ_0 为 $0.01t_0$ 。

2.2 模型流程与构建步骤

为了能够准确地预测大坝变形趋势,将 CEEMDAN 和 VMD 相融合形成二次模态分解,并与 DBO 优化的 BiLSTM 神经网络相结合,构建了基于二次模态分解-DBO-BiLSTM 的大坝变形预测模型。大坝原始数据通过 CEEMDAN 分解得到 n 个分量,利用 VMD 对其高频非平稳性分量继续分解得到 K 个分量,并采用 PE 算法将所有分量分为三类,将其训练集分量以及影响因子变量输入到 BiLSTM 模型中进行训练,此时需要确定 BiLSTM 模型的两个隐藏层节点数、学习率和训练次数。为了提高预测精度,缩短训练时间,利用 DBO 算法进行优化得到最优参数值,其流程如图 1 所示。

该模型构建具体步骤如下:

步骤 1 数据预处理,利用 CEEMDAN 对大坝变形数据进行分解,得到各个分量,并利用 VMD 对




图 1 二次模态分解和深度学习模型的流程

其高频非平稳性分量再次分解,得到一系列分量。
步骤 2 利用 PE 算法对各个分量按照其不同特性进行分组,分为三类分量,即趋势性分量、周期性分量和随机性分量。
步骤 3 将各类分量划分为训练集和测试集。
步骤 4 选择待优化参数,将 BiLSTM 网络模型中两个隐藏层节点数、学习率和训练次数作为寻优对象。

步骤 5 初始化 DBO 算法的参数,包括种群大小、最大迭代次数以及待优化参数的取值范围。
步骤 6 输入预处理后的训练集数据及影响因素,利用 DBO 算法进行寻优,计算各种群适应度值,更新所有蜣螂的位置,并对当前最优解及适应度值进行更新,直到符合最优解要求结束计算,输出最优参数到 BiLSTM。

步骤 7 利用参数寻优后的 BiLSTM 模型对各类分量测试集进行预测,将各分量预测结果叠加求和同时反归一化处理得到最终预测结果。

3 工程实例验证

3.1 工程简介

本文数据来源于江西省某水电站大坝的变形监测数据,选取 2008 年 8 月 13 日至 2011 年 5 月 9 日期间上游库水位数据以及引张线 EX8 监测点水平位移监测数据,共 1 000 期数据,选取前 705 期大坝变形数据为训练集,后 295 期数据为测试集,如图 2 所示。由图 2 可见,监测点的水平位移变形数据具有明显的非线性和非平稳性特征,以此为基础来进行本文提出模型的大坝变形预测研究。

3.2 大坝变形数据的二次模态分解

首先对 EX8 监测点的数据进行 CEEMDAN 模




图2 大坝监测原始数据

态分解,参考文献[16]以及多次试验测试结果,设置加入500组高斯白噪声信号,标准差设为0.2,如图3所示。原始变形时间序列被分解为10组不同频率尺度的IMF分量,其频率由高到低,波形也越来越平滑。




图3 CEEMDAN 分解分量

从图3中可看出,经过CEEMDAN分解得到的IMF1分量显示出高频率不规则波形,具有明显的高频非平稳性特征,若对其直接进行预测则会产生较大的误差,因此利用VMD对其进行二次模态分解,实现数据平稳化处理。在VMD分解过程中,分解层数的选择决定了分解效果的好坏,为避免过分解和欠分解的现象发生,参考Li等^[17]提出的中心频率法,确定其分解层数取5,分解得到5组不同频率尺度的子分量,如图4所示。从图4中可看出,经过VMD二次模态分解后得到的5组分量频率平稳,呈现周期性波动规律。






图4 VMD 分解分量

考虑经过二次模态分解后的分量过多,若全部进行训练预测,则会大幅度提高计算量,并且容易忽视它们之间的相关性,从而降低数据的表征能力。基于PE算法具备度量数据复杂性的特征,本文应用PE算法对各分量进行熵值计算从而重构分量。将CEEMDAN分解得到的分量记为IMF1至IMF10,VMD分解得到的分量记为IMF11至IMF15,其结果如图5所示。从图5可知,IMF1至IMF10的排列熵值逐渐递减,体现出其频率逐渐降低,随机性逐渐减弱的特征。同时,对IMF1进行VMD分解后,其子分量IMF11至IMF15的排列熵明显比IMF1低,且趋于平稳,有利于提高预测精度。通过比较各分量熵值间的接近程度与大小对各IMF分量进行重构,其中IMF分量2、3、12~14的熵值接近且都大于0.65,具有明显的随机性,视为高频随机性分量;IMF分量7~10的熵值接近且都小于0.25,视为低频趋势性分量;IMF分量4~6、11、15的熵值居中且



(a) 模态分量的排列熵



(b) 三类分量的变化趋势

图5 排列熵计算分类结果

较为接近,视为中频周期性分量。

3.3 模型训练及预测结果分析

3.3.1 模型训练

将上述三类分量的训练集数据分别构建 DBO-BiLSTM 模型,并输入影响因素,同时为避免模型出现过拟合现象,在训练过程中加入 Dropout 算法进行正则化处理。在训练过程中,利用 DBO 算法对 BiLSTM 神经网络的两个隐藏层节点数、学习率和训练次数进行优化。经过多次试验测试,本文将上述 4 个参数取值范围分别设为 [1, 100]、[1, 100]、[0.001, 0.01]、[1, 200]。参考文献 [15],将 DBO 算法进行初始化,其种群大小设为 10,最大迭代次数设为 30。通过 DBO 算法训练得到的三类分量 BiLSTM 的超参数如表 1 所示。

表 1 三类分量预测参数

分量	隐藏层 L1 节点数	隐藏层 L2 节点数	学习率	训练次数
趋势性分量	73	100	0.010 0	200
周期性分量	88	63	0.008 1	124
随机性分量	100	78	0.009 9	200

3.3.2 模型预测结果分析

将三类分量的测试集数据及影响因素输入到优化参数后的模型中,预测所对应的变形位移值,将各个分量预测值相加得到最后的预测结果。预测结果如图 6 所示,可看出二次模态分解-DBO-BiLSTM 模型的预测值基本都落在了 95% 预测带区间内,预测值与实测值的拟合效果好,表明本文提出的基于二次模态分解-DBO-BiLSTM 的大坝变形预测模型能够得到精度较高的预测值,且鲁棒性较优。




图 6 二次模态分解-DBO-BiLSTM 模型预测结果

为验证二次模态分解-DBO-BiLSTM 预测模型的性能,将其与支持向量机(support vector machine, SVM)模型、LSTM 模型、BiLSTM 模型和 CEEMDAN-DBO-BiLSTM 模型进行对比验证,采用统一的原始数据作为输入,LSTM 和 BiLSTM 模型统一设置 50 个隐含层节点数以及 100 次的模型训练次数,DBO 和 CEEMDAN 算法参数设置与二次模态分解-DBO-BiLSTM 模型参数设置一致,采用均方根误差 (RMSE)、平均绝对误差 (MAE)、决定系数 (R^2) 作

为模型预测效果的评价指标。各模型预测结果如图 7 所示,各模型的评估指标如表 2 所示。




图 7 各预测模型预测结果

表 2 各预测模型的预测性能对比

模型	RMSE/mm	MAE/mm	R^2
SVM	0.223	0.148	0.943
LSTM	0.126	0.082	0.953
BiLSTM	0.103	0.076	0.968
CEEMDAN-DBO-BiLSTM	0.080	0.058	0.985
二次模态分解-DBO-BiLSTM	0.073	0.056	0.988

从图 7 可以看出:①从单一预测模型对比可知,BiLSTM 模型和 LSTM 模型要比 SVM 模型的预测结果理想,SVM 模型整体的预测曲线与实测曲线偏差较大,这说明与浅层机器学习相比,深度学习能够更好地挖掘并学习训练大坝变形数据之间复杂的非线性关系;②与 LSTM 模型相比,BiLSTM 模型预测曲线更贴合实测曲线,在 170 ~ 200 期的预测值与实测值没有表现出明显的差异,这说明 BiLSTM 能够更好地利用空间数据信息,学习前后两个方向上信息的特征;③相比单一预测模型,引入模态分解技术的组合模型预测效果更好,在拐点上具有更好的拟合效果,说明 CEEMDAN 分解可降低大坝变形数据的非线性和非平稳性对预测精度的影响;④相比一次模态分解,经过二次模态分解的 DBO-BiLSTM 模型预测效果更好,总体看来预测值与实际值基本一致,波动周期也近似,能够真实反映出监测点位移的变形趋势,这表明经过对高频非平稳分量的再次分解后模型能更好地挖掘大坝变形非线性数据中的有用信息。计算各预测模型的残差可知,本文模型的残差均值位于零值附近,波动范围最小,呈现正态分布,具有更强的预测稳定性。从表 2 可看出,二次模态分解-DBO-BiLSTM 模型的 3 项评价指标明显优于 SVM、LSTM、BiLSTM 模型,略优于 CEEMDAN-DBO-BiLSTM 模型,表明其预测精度更高,误差更小。

4 结 语

为提高大坝变形预测精度,本文基于“分解-预

测-重构”的思想,构建了基于二次模态分解-DBO-BiLSTM 的组合预测模型。将 CEEMDAN 和 VMD 相结合应用于大坝变形数据预处理,有效降低了 CEEMDAN 一次模态分解中产生的高频非平稳分量对预测精度的影响,提高了原始数据的表征能力,实现了数据的平稳化处理。同时,采用 BiLSTM 神经网络并引入 DBO 对其优化超参数,能够有效地学习输入信息的前后拓扑关系,更全面地挖掘数据中的有效信息,提高了模型的泛化能力以及预测精度。工程实例测试结果表明,二次模态分解-DBO-BiLSTM 模型的预测精度明显优于 SVM、LSTM、BiLSTM 和 CEEMDAN-DBO-BiLSTM 模型,验证了该模型在大坝变形预测上的准确性和可行性。

参考文献:

[1] 张建中,顾冲时,袁冬阳,等. 基于优化 VMD 与 GRU 的混凝土坝变形预测模型[J]. 水利水电科技进展,2023,43(5):38-44. (ZHANG Jianzhong, GU Chongshi, YUAN Dongyang, et al. Deformation prediction model of concrete dams based on optimized VMD and GRU[J]. Advances in Science and Technology of Water Resources, 2023, 43(5):38-44. (in Chinese))

[2] 向镇洋,包腾飞,白妍丽,等. 基于混合注意力机制和深度学习的大坝变形预测模型[J]. 水利水电科技进展,2023,43(2):96-101. (XIANG Zhenyang, BAO Tengfei, BAI Yanli, et al. Dam deformation prediction model based on mixed attention mechanism and deep learning[J]. Advances in Science and Technology of Water Resources, 2023, 43(2):96-101. (in Chinese))

[3] 郭张军,黄华东,屈旭东. 基于深度学习的大坝变形预测模型[J]. 水电能源科学,2020,38(3):83-86. (GUO Zhangjun, HUANG Huadong, QU Xudong. Deep learning-based model for dam deformation prediction[J]. Hydropower Energy Science, 2020, 38(3):83-86. (in Chinese))

[4] 胡安玉,包腾飞,杨晨蕾,等. 基于 LSTM-Arima 的大坝变形组合预测模型及其应用[J]. 长江科学院院报,2020,37(10):64-68. (HU Anyu, BAO Tengfei, YANG Chenlei, et al. Combined LSTM-Arima-based prediction model for dam deformation and its application[J]. Journal of the Changjiang Academy of Sciences, 2020, 37(10):64-68 (in Chinese))

[5] 宋洋,杨杰,宋锦焄,等. 基于 CEEMDAN-PE-LSTM 的混凝土坝变形预测[J]. 水利水运工程学报,2021,187(3):41-49. (SONG Yang, YANG Jie, SONG Jingtao, et al. Concrete dam deformation prediction based on CEEMDAN-PE-LSTM model[J]. Journal of Hydraulic and Hydrological Engineering, 2021, 187(3):41-49. (in Chinese))

[6] 董泳,刘肖峰,李云波,等. 基于 EMD-EEMD-LSTM 的大坝变形预测模型[J]. 水力发电,2022,48(10):68-71. (DONG Yong, LIU Xiaofeng, LI Yunbo, et al. Dam deformation prediction model based on EMD-EEMD-LSTM

[J]. Hydropower, 2022, 48(10):68-71. (in Chinese))

[7] 陈竹安,熊鑫,游宇垠. 变分模态分解与长短时神经网络的大坝变形预测[J]. 测绘科学,2021,46(9):9. (CHEN Zhu'an, XIONG Xin, YOU Yuyin. Dam deformation prediction by variational modal decomposition and long short-term neural network[J]. Survey and Mapping Science, 2021, 46(9):9. (in Chinese))

[8] 张明岳,李丽敏,温宗周. 基于变分模态分解和双向长短时记忆神经网络模型的滑坡位移预测[J]. 山地学报,2021,39(6):855-866. (ZHANG Mingyue, LI Limin, WEN Zongzhou. Landslide displacement prediction based on variational modal decomposition and bidirectional long short-term memory neural network model[J]. Journal of Mountain Science, 2021, 39(6):855-866. (in Chinese))

[9] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E, et al. Noise-assisted EMD methods in action[J]. Advances in Adaptive Data Analysis, 2012, 4(4):1250025.

[10] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.

[11] GRAVES A. Long short-term memory: supervised sequence labelling with recurrent neural networks[M]. Berlin:Springer, 2012:37-45.

[12] 谢小瑜,周俊煌,张勇军,等. 基于 W-BiLSTM 的可再生能源超短期发电功率预测方法[J]. 电力系统自动化,2021,45(8):175-184. (XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun, et al. W-BiLSTM based ultra-short-term power prediction method for renewable energy[J]. Power System Automation, 2021, 45(8):175-184. (in Chinese))

[13] GRAVES A, SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks: the Official Journal of the International Neural Network Society, 2005, 18(5):602-610.

[14] 张栋栋,陈洁,李洋. 基于 VMD-SE 和 BiLSTM 在短期负荷预测应用[J]. 现代电子技术,2021,44(23):155-159. (ZHANG Dongdong, CHEN Jie, LI Yang. Based on VMD-SE and BiLSTM in short-term load forecasting applications[J]. Modern Electronics Technology, 2021, 44(23):155-159. (in Chinese))

[15] XUE Jiankai, SHEN Bo. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2022, 79(7):7305-7336.

[16] 陈伟,吕学斌,梁雪春. 基于 CEEMDAN-LSTM 的陶岔渠首水深预测[J]. 人民黄河,2022,44(5):89-94. (CHEN Wei, LYU Xuebin, LIANG Xuechun. Water depth prediction at the head of Taocha canal based on CEEMDAN-LSTM[J]. Yellow River, 2022, 44(5):89-94. (in Chinese))

[17] LI Hua, LIU Tao, WU Xing, et al. An optimized VMD method and its applications in bearing fault diagnosis[J]. Measurement, 2020, 166:108185.

(收稿日期:2023-05-07 编辑:骆超)