

混合变分模态长短期记忆网络水库表面位移形变预测

孙喜文¹, 贺小星^{2*}, 鲁铁定¹, 王海城³, 张云涛⁴, 陈红康¹

(1. 东华理工大学 测绘与空间信息工程学院, 江西 南昌 330013; 2. 江西理工大学 土木与测绘工程学院, 江西 赣州 341000; 3. 河北省水利水电勘测设计研究院集团有限公司, 河北 石家庄 050085; 4. 河北省水利工程局集团有限公司, 河北 石家庄 050021)

摘要:为提高水库位移形变预测精度,通过改变变分模态分解(variational mode decomposition, VMD)的分解方式,融合 VMD 与长短期记忆网络对非线性非平稳的水库位移形变进行预测,提出了一种混合变分模态长短期记忆网络(mix variational mode decomposition long short-term memory, MVMDLSTM)模型预测方法;对不同单一预测模型与组合模型采用多源数据集验证新方法的可靠性。实验结果表明: MVMDLSTM 模型能有效减弱单一预测模型与经验模态分解组合模型估计的偏差, MVMDLSTM 模型预测精度更优,为稳定监测水库慢滑移和蠕动等微小变形预测预警提供有效的数据决策。

关键词:变分模态分解; 人工神经网络; 长短期记忆网络; 形变预测

中图分类号: P228 文献标志码: A 文章编号: 1001-2486(2025)03-151-11



论文
拓展

Mix variational mode decomposition long short-term memory for predicting of reservoir surface displacement and deformation

SUN Xiwen¹, HE Xiaoxing^{2*}, LU Tieding¹, WANG Haicheng³, ZHANG Yuntao⁴, CHEN Hongkang¹

(1. School of Surveying and Geoinformation Engineering, East China University of Technology, Nanchang 330013, China; 2. School of Civil and Mapping Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China; 3. Hebei Institute of Investigation and Design of Water Conservancy and Hydropower Co., Ltd., Shijiazhuang 050085, China; 4. Hebei Water Conservancy Engineering Bureau Group Limited, Shijiazhuang 050021, China)

Abstract: In order to improve the prediction accuracy of the displacement and deformation of reservoir, the displacement and deformation of non-linear and non-stationary reservoir was predicted by changing the decomposition method of VMD (variational mode decomposition) and integrating VMD and long short-term memory. A MVMDLSTM (mixed variational mode decomposition long short-term memory) model prediction method was proposed. The reliability of the new method was verified with multi-source datasets for different single prediction models and combined models. The experimental results show that the MVMDLSTM model can effectively attenuate the bias of the single prediction model and the empirical mode decomposition combination model estimation, and the prediction accuracy of the MVMDLSTM model is better, which provides an effective data decision-making for the stable monitoring of the prediction and warning of the reservoir's slow sliding and creeping and other small deformations.

Keywords: variational mode decomposition; artificial neural network; long short-term memory network; deformation prediction

据统计,我国建设的各类型大坝包括水库大坝等已累计约 10 万座,对水库大坝的监测类型包括表面位移、浸润线、库水位、雨量、最小干滩、内部位移、渗流等,精准预测水库表面位移

形变对确保洋河水库安全运营具有非常重要的意义。

水库大坝监测设备和监测数据随着监测范围的扩大而越来越庞大,使用传统的监测和管

收稿日期:2023-04-10

基金项目:国家自然科学基金资助项目(42374040,42061077,42104023,42364002);江西省主要学科科学技术带头人培养计划资助项目(20225BCJ23014);东华理工大学研究生创新专项基金资助项目(DHYC-202304)

第一作者:孙喜文(1993—),女,江苏徐州人,博士研究生,E-mail: xwsun@ecut.edu.cn

*通信作者:贺小星(1986—),男,江西萍乡人,副教授,博士,硕士生导师,E-mail: xhx@jxust.edu.cn

引用格式:孙喜文,贺小星,鲁铁定,等.混合变分模态长短期记忆网络水库表面位移形变预测[J].国防科技大学学报,2025,47(3):151-161.

Citation: SUN X W, HE X X, LU T D, et al. Mix variational mode decomposition long short-term memory for predicting of reservoir surface displacement and deformation[J]. Journal of National University of Defense Technology, 2025, 47(3): 151-161.

理模式工作量特别大,且受天气等各种因素影响,难以做到实时监测。全球导航卫星系统(global navigation satellite system, GNSS)具有高精度、多功能、全天候、高效率、广应用、易操作、自动化等特点,随着 GNSS 技术精度的不断提升,GNSS 在灾害监测预警、防范中起到了重要作用^[1]。

GNSS 大坝变形数据时间序列具有明显的多尺度特征且为非平稳时间序列,文献[2]通过经验模态分解(empirical mode decomposition, EMD)与径向基函数(radial basis function, RBF)神经网络方法探讨了大坝非线性周期信号变化的内在规律,RBF 方法可提升精度 50% 以上且泛化能力强。文献[3]将大坝在不同时段的位移数据作为一时间序列,通过本身数据时间进行形变预测。文献[4-5]通过集合经验模态分解(ensemble empirical mode decomposition, EEMD)方法对大坝、边坡进行预测,但分解的分量个数随机,分解层数偏大而导致数据泄露。文献[6]提出了自适应 EMD 方法,分析 20 世纪 90 年代的非线性和非平稳过程。EMD 方法基于时间序列的局部性质,适应性地、有效地将时间序列分解为具有不同频带的稳态本模函数和残差,EMD 的有效性已经在非线性和非平稳过程的分析中得到了广泛的应用^[7],但 EMD 的应用过程中仍存在一些局限性,如模式混合问题。长短期记忆网络(long short-term memory, LSTM)能够有效地解决循环神经网络中间隔较长的预测时间序列,涌现新颖的预测框架处理时间序列预测问题^[8-10]。文献[11]结合变分模态分解(variational mode decomposition, VMD)和 LSTM 的预测模型,累加各模态分量的预测值完成重构,通过试凑法确定分割窗口长度,但选择的序列较短,无法解决水库长时间位移形变序列的非平稳、非线性问题。

因此,为实现水库大坝长时间序列的位移形变预测,本文提出一种改进的混合变分模态长短期记忆网络(mix variational mode decomposition long short-term memory, MVMDLSTM)模型预测方法,通过改进的 VMD 将水库表面位移序列进行分解重构为干净的序列,将其作为特征值代入 LSTM 进行预测,同时利用不同数据集与组合模型方法,如基于人工神经网络(artificial neural network, ANN)的 VMDANN 等模型验证 MVMDLSTM 模型预测的有效性与稳定性。通过改进 MVMDLSTM 法对位移形变监测数据进行预

测,建立多尺度形变预测模型,可提高水库位移形变预测精度及计算结果的可靠性,为建立水库大坝预测与预警决策模型、加强系统管理及安全运营提供了科学有效的解决方法。

1 模型构建

1.1 变分模态分解

变分模态分解 VMD 是一种通过迭代寻找变分模型最优解,确定各分量的中心频率和有限带宽的内涵模态分量(intrinsic mode functions, IMF),从而自适应地实现信号的频域划分和各分量有效分离的一种信号分解方法。通过 VMD 得到了 k 阶特征模函数的表达式^[12],即

$$F_u = A_k(t) \cos(\phi_k(t)) \quad (1)$$

$$F_\omega = \phi_k'(t) = \frac{d\phi_k(t)}{dt} \quad (2)$$

其中: F_u 为 $u_k(t)$ 函数; $A_k(t)$ 为 $u_k(t)$ 的瞬时振幅; $k=1,2,\dots,K$; F_ω 为 $\omega_k(t)$ 函数, $\omega_k(t)$ 为 $u_k(t)$ 的中心频率; $\phi_k(t)$ 为非单调递减的相位函数。通过 Hilbert 变换得到 $u_k(t)$ 的解析信号,从而获得单边频谱^[13],即

$$\left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) \quad (3)$$

式中, $\delta(t)$ 为脉冲函数, j 表示该时刻。通过调整每个 $u_k(t)$ 的中心频率 $\omega_k(t)$,并将其与各模式的单边频谱混合,得到基带信号:

$$\left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \quad (4)$$

计算解调信号梯度,得到解调信号的带宽,并建立以下约束变分模型表达式^[14]:

$$\min_{\{\mu_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (5)$$

$$\text{s. t. } \sum_{k=1}^K u_k(t) = f \quad (6)$$

其中: f 表示为 $f(t)$,代表输入信号; $\{\mu_k\} = \{\mu_1, \mu_2, \dots, \mu_k\}$ 为 k 个模态分量, $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 为 k 个模态分量对应的频率中心。再引入二阶惩罚因子与拉格朗日乘子转换为无约束变分问题,得到的扩展拉格朗日表达式如下:

$$L(\{\mu_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (7)$$

式中, α 为惩罚因子, $\lambda(t)$ 为拉格朗日乘子,“ \langle, \rangle ”表示内积。用乘子交替方向法不断交替更

新 \hat{u}_k^{n+1} , 当满足公式

$$\sum_{k=1}^k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (8)$$

迭代结束, 得到 k 个模态分量值。其中 ε 为收敛容差。

1.2 人工神经网络

人工神经网络 ANN 是对人脑神经网络的某种抽象、简化和模拟后建立的复杂网络结构。建立包含输入层、隐含层和输出层的神经网络结构是机器学习的主要工具之一, ANN 结构如图 1 所示^[15]。

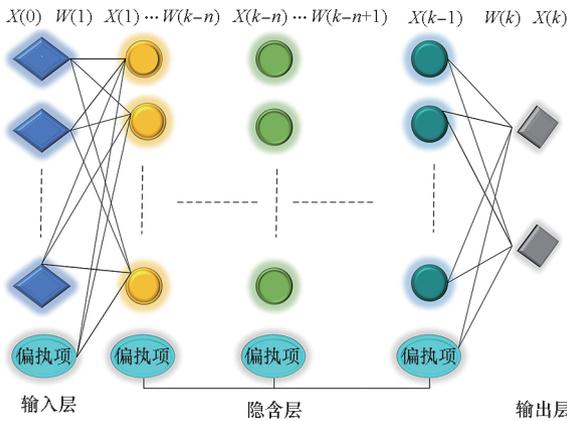


图 1 ANN 结构示意图

Fig. 1 ANN structure diagram

1.3 长短期记忆网络

Jonathans 首次提出长短期记忆网络 LSTM 是一种改进的循环神经网络^[16] (recurrent neural networks, RNN), 能够有效地解决循环神经网络中间隔较长的预测时间序列^[17], 但其尚未被应用于洋水水库表面位移形变预测中。LSTM 结构示意图^[11]如图 2 所示。

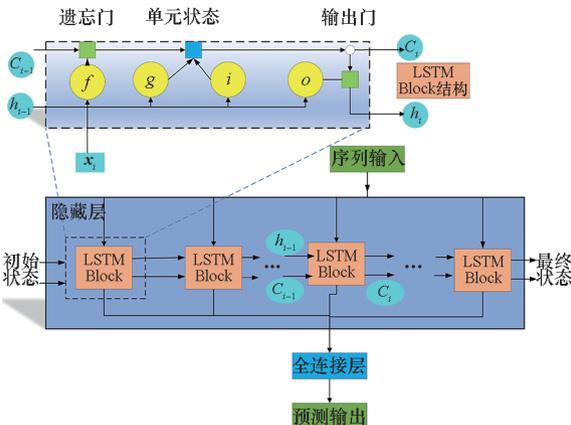


图 2 LSTM 结构示意图

Fig. 2 Schematic diagram of LSTM structure

时间序列从输入层开始, 经 LSTM 层, 到达连

接层, 最后预测输出, h_i 为隐藏状态, C_i 为单元状态。单个 LSTM Block 模块如图 2 所示, 包括输入门 i 、单元状态 g 、遗忘门 f 及输出门 o , 其数学模型为:

$$\begin{cases} i_t = \sigma(W_i[x_t, h_{t-1}] + b_i) \\ f_t = \sigma(W_f[x_t, h_{t-1}] + b_f) \\ g_t = \tanh(W_g[x_t, h_{t-1}] + b_g) \\ o_t = \sigma(W_o[x_t, h_{t-1}] + b_o) \end{cases} \quad (9)$$

式中, W 为各单元权重矩阵, $[x_t, h_{t-1}]$ 为两个方向构成的长向量, b 为偏置矩阵, σ 表示 sigmoid 函数。

1.4 MVMDLSTM 模型构建

水库位移时间序列是一组非线性的时间序列, 如果从原始站时间序列直接进行预测, 会引起较大误差, 而 VMD 能更好更有效地提取时间序列的特征值。为了降低水库位移时间序列的非线性变化, 本文融合 VMD 与 LSTM 模型建立预测精度较高的 MVMDLSTM 模型。

将一维水库位移序列进行 VMD 分解, 得到 k 个子序列, 原始序列定义^[11]为:

$$F_k = \{f_k(1), f_k(2), \dots, f_k(n)\} \quad (10)$$

设前 m 组序列为训练集与验证集, 表示为 X_{Tk} , 则 X_{Tk} 表示为:

$$X_{Tk} = \{f_k(1), f_k(2), \dots, f_k(m)\} \quad (11)$$

余下 $n - m$ 组序列作为测试集, 表示为 X_{Ck} , 则 X_{Ck} 表示为:

$$X_{Ck} = \{f_k(m+1), f_k(m+2), \dots, f_k(n)\}, m < n, n \in \mathbb{N} \quad (12)$$

对原始时间序列进行分割, 设置分割长度为 L , 则分割后序列为:

$$\begin{aligned} X'_k &= \{f_k(1)f_k(2) \dots f_k(n-L+1), f_k(2)f_k(3) \dots \\ & f_k(n-L+2), \dots, f_k(L)f_k(L+1) \dots f_k(n)\} \end{aligned} \quad (13)$$

设 X_{Tk} 的输入为 X'_{Tk} , X_{Tk} 输出为 Y'_{Tk} , 其表达式为:

$$\begin{aligned} X'_{Tk} &= \{f_k(1)f_k(2) \dots f_k(n-L-2), f_k(2)f_k(3) \dots \\ & f_k(n-L-1), \dots, f_k(L)f_k(L+1) \dots f_k(n-3)\} \end{aligned} \quad (14)$$

$$\begin{aligned} Y'_{Tk} &= \{f_k(2)f_k(3) \dots f_k(n-L-1), f_k(3)f_k(4) \dots \\ & f_k(n-L), \dots, f_k(L+1)f_k(L+2) \dots f_k(n-2)\} \end{aligned} \quad (15)$$

设 X_{Ck} 输入为 X'_{Ck} , X_{Ck} 输出为 Y'_{Ck} , 其表达式为:

$$\begin{aligned} X'_{Ck} &= \{f_k(3)f_k(4) \dots f_k(n-L), f_k(4)f_k(5) \dots \\ & f_k(n-L+1), \dots, f_k(L+2)f_k(L+3) \dots f_k(n-1)\} \end{aligned} \quad (16)$$

$$Y'_{Ck} = \{f_k(4)f_k(5) \cdots f_k(n-L+1), f_k(4)f_k(5) \cdots f_k(n-L+2), \cdots, f_k(L+3)f_k(L+4) \cdots f_k(n)\} \quad (17)$$

将水库位移序列进行 VMD 分解后得到 a 个模态分量与残差 r 值,通过不同参数 K 值得到相应的模态分量,将分解后得到的模态分量相加得到融合后的模态分量 MIXIMF;再将原时间序列的测试集按列合并得到融合的 VMD,表示为 MIXVMD;将 MIXVMD 作为模型特征代入 LSTM 进行预测。为了验证 MVMDLSTM 的预测精度,同时将 MIXVMD 作为模型特征代入 ANN 进行对比预测,并对预测结果进行精度分析。本文构建的 MVMDLSTM 预测模型框架如图 3 所示, MVMDLSTM 模型设计参数如表 1 所示。

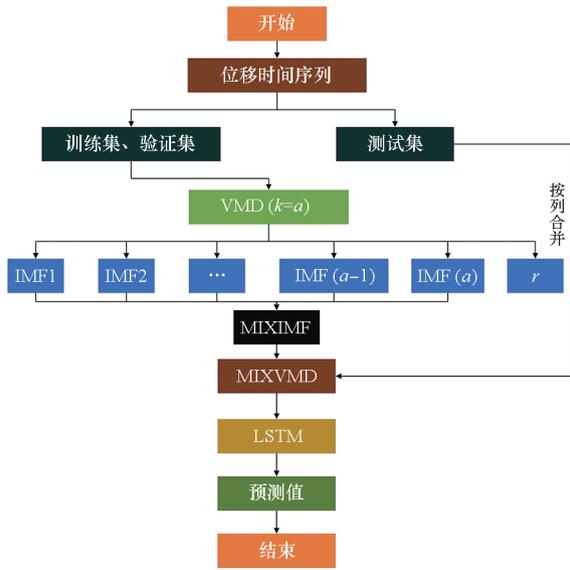


图 3 MVMDLSTM 预测模型框架图

Fig. 3 MVMDLSTM prediction model framework diagram

表 1 MVMDLSTM 预测模型设计参数

Tab. 1 Design parameters of MVMDLSTM prediction model

参数	MVMDLSTM 参数值
学习率	0.001
迭代次数	50
隐藏层	128
批尺寸	16
测试集长度	300
验证集长度	300
训练集长度	2 400

1.5 精度评价指标

采用均方根误差 (root mean square error,

RMSE)、平均绝对误差 (mean absolute error, MAE) 两个指标进行评价,数学模型^[18]为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \quad (19)$$

其中, y_i 为原始位移序列, \hat{y}_i 为各模型的预测结果, n 为水库数据数量。RMSE、MAE 值越小代表该模型预测精度越高,反之,则说明该模型预测精度较低。为了判断 MVMDLSTM 模型预测精度的效果,本文设 Q 表示精度提升幅度, O 与 O' 分别表示初始模型和组合模型 (即优化后的模型) 的精度评价指标 (如 RMSE、MAE), Q 越大说明组合模型提升幅度越大。则 Q 数学表达式为:

$$Q = \frac{O - O'}{O} \quad (20)$$

2 实例分析

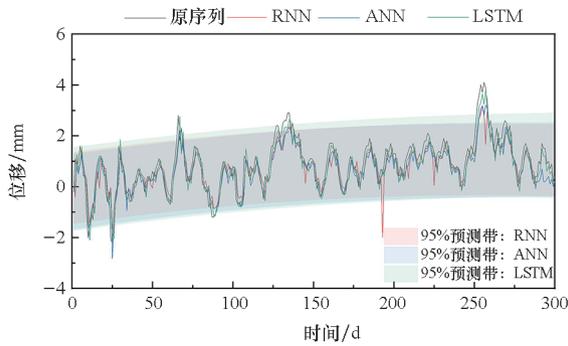
为验证 MVMDLSTM 模型预测精度的效果,以洋河水库 2014 年 9 月—2022 年 11 月的表面位移形变数据为例,以天为观测间隔,观测方向包括北方向 N、东方向 E 及垂向 U。利用水库迎 1A、副坝 26G、马 13A 三个站点的数据集,经预处理后将 3 000 组数据进行分割,前 2 400 组为训练集、中间 300 组为验证集、后 300 组为测试集,采用 RMSE、MAE 进行预测精度评价。因数据量较大,所用设备处理器为 i7-12700H, CPU 为 2.70 GHz,机带 RAM 为 32 GB 的 64 位 Windows11 系统。

2.1 单模型预测分析

本文所用 MVMDLSTM 模型为组合模型,为了对比组合模型预测精度的效果,采用 RNN、ANN 与 LSTM 的单一模型进行对比,以迎 1A 站为例,RNN、ANN 与 LSTM 测试集预测北方向 N、东方向 E 及垂向 U 结果曲线如图 4 所示。

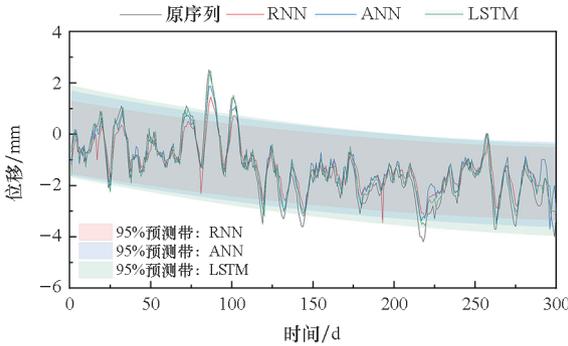
图 4 中 95% 预测带表示拟合后该模型预测结果包含 95% 数据点的区域。由图可知,单一 RNN、ANN 与 LSTM 模型在北方向、东方向预测结果具有一定的偏差,RNN、ANN 与 LSTM 模型预测的结果曲线在原始序列基础上下移,尤其在垂向下移明显,预测结果不理想。单一模型预测精度评价如表 2 所示。

由表 2 可知,单一模型预测精度在垂向变化较大,且 LSTM 模型预测结果精度更好。如马



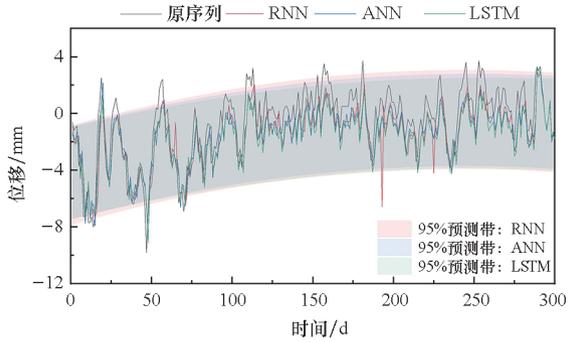
(a) 北方向预测结果曲线

(a) Prediction result curve of the north direction



(b) 东方向预测结果曲线

(b) Prediction result curve of the east direction



(c) 垂向预测结果曲线

(c) Prediction result curve of the up direction

图4 三方向预测结果曲线分布

Fig.4 Curve distribution of predicted results in three directions

13A站垂向 LSTM模型的RMSE(1.37 mm)比ANN模型的RMSE(2.19 mm)降幅达37.4%; ANN在部分场景下表现较差,如副坝26G站东方向ANN模型的RMSE(1.27 mm)与LSTM模型的RMSE(0.66 mm)相比误差接近2倍;在马13A站垂向,ANN模型(RMSE为2.19 mm)与RNN模型(RMSE为2.24 mm)误差相近,说明单一ANN与RNN模型难以处理非线性时序特征。LSTM的RMSE和MAE在北方向与东方向普遍低于RNN和ANN模型,在垂向的改进尤为显著。

表2 不同单一模型预测精度

Tab.2 Prediction accuracy of different single model
单位:mm

站点	方向	指标	RNN	ANN	LSTM
迎1A	N	RMSE	0.55	0.81	0.53
		MAE	0.45	0.66	0.41
	E	RMSE	0.56	0.59	0.50
		MAE	0.46	0.42	0.35
	U	RMSE	1.60	1.93	1.57
		MAE	0.29	1.48	1.24
副坝26G	N	RMSE	0.79	1.22	0.75
		MAE	0.60	0.99	0.65
	E	RMSE	0.85	1.27	0.66
		MAE	0.65	0.99	0.53
	U	RMSE	1.55	2.60	1.45
		MAE	1.21	2.08	1.10
马13A	N	RMSE	0.65	1.12	0.59
		MAE	0.52	0.90	0.45
	E	RMSE	0.47	0.53	0.41
		MAE	0.38	0.44	0.33
	U	RMSE	2.24	2.19	1.37
		MAE	1.93	1.90	1.09

综上所述图4与表2可知,在大坝形变预测中优先采用LSTM模型,且预测精度更高。但单一模型RNN、ANN与LSTM模型均不能准确预测水库位移序列,预测结果与原始位移序列拟合度较差。

2.2 MVMDLSTM 预测分析

2.2.1 参数K值选取

VMD参数K的选取是解决变分问题最优解的重要步骤,为了取得更好的预测精度,以北方向迎1A站位移序列为例,不同K值预测结果误差如图5所示,各站点 α 取值见表3。

本文通过网格搜索的方法对MVMDLSTM模型中K值进行选取,当K值过大时会造成模型载荷的梯度上升,影响预测效果。由图5可知,当 $K=4, \alpha=196$ 时, MVMDLSTM模型预测的均方根误差为0.46 mm,平均绝对误差为0.36 mm, MVMDLSTM模型预测精度最高。

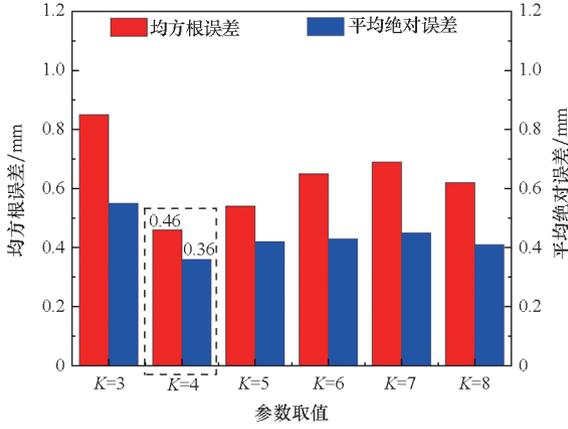


图 5 不同参数 K 值误差对比

Fig. 5 Comparison of errors for different parameters K

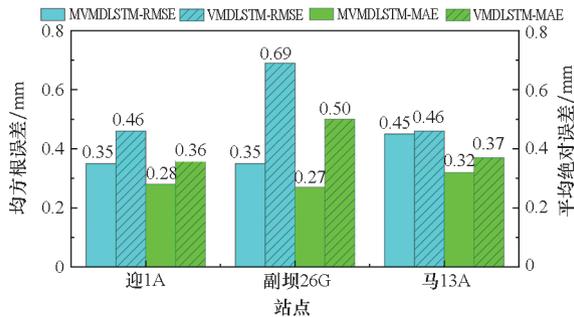
表 3 K=4 时不同方向的 α 值

Tab. 3 Values of α in different directions for K=4

站点	N	E	U
迎 1A	196	200	167
副坝 26G	277	183	272
马 13A	376	293	383

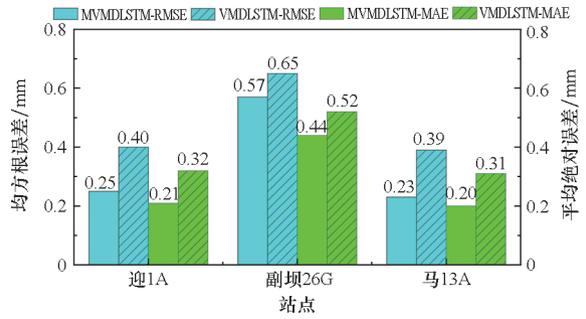
2.2.2 VMD 组合模型结果分析

单一模型均不能准确预测水库位移序列,预测结果与原始位移序列拟合度较差。本文构建 VMD 与不同预测模型进行验证,组合模型为 VMDANN、VMDRNN 与 VMDLSTM。特别注意的是,目前组合算法中将 VMD 与 LSTM 进行融合时,先将训练集、验证集与测试集一同分解,再对分解后的各模态分量代入模型进行预测,然后将各分量预测结果相加得到最终预测结果;而本文的新算法是将分解后得到的模态分量相加得到融合后的模态分量 MIXIMF,再将原时间序列的测试集按列合并得到融合的 MIXVMD。VMDLSTM 与 MVMDLSTM 评价指标如图 6 所示。



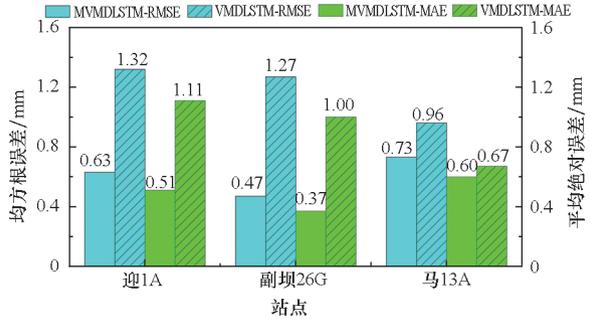
(a) 北方向各站点评价指标

(a) Evaluation index of each site in the north direction



(b) 东方向各站点评价指标

(b) Evaluation index of each site in the east direction



(c) 垂向各站点评价指标

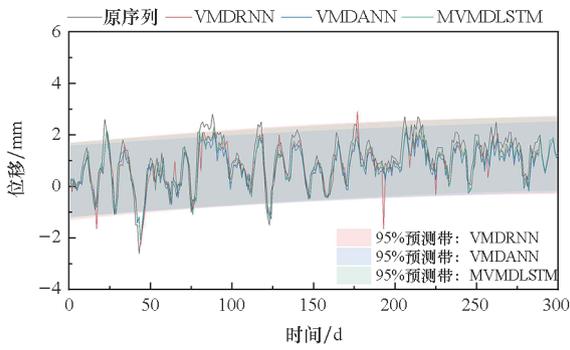
(c) Evaluation index of each site in the up direction

图 6 VMDLSTM 与 MVMDLSTM 评价指标对比

Fig. 6 Comparison of evaluation indicators between VMDLSTM and MVMDLSTM

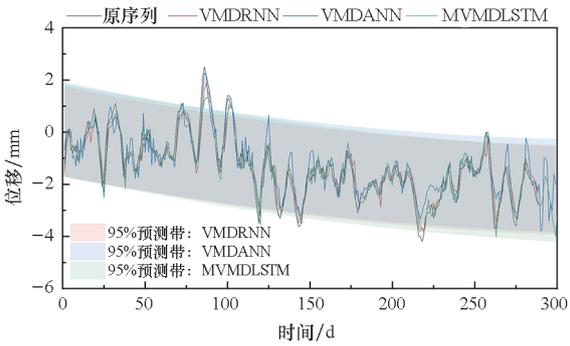
由图 6 可知,VMDLSTM 模型在北方向、东方向、垂向预测的均方根误差与平均绝对误差值均虚高,如果采用 VMDLSTM 模型有两点不足^[19-20]:①训练集、验证集与测试集数据一同进行 VMD 会导致训练集中数据大小受到测试集中数据的影响,相当于测试集中数据已知,造成信息泄露;②训练集、验证集与测试集数据一同进行 VMD 后的各模态分量及残差与原数据起伏波动相差较大且相关性较弱。本文之后不再将 VMDLSTM 模型与其他组合模型进行对比分析。

洋河水库位移时间序列具有非线性非平稳的特性,采用单一的 RNN、ANN 与 LSTM 模型会影响预测精度,可能导致预测结果产生偏差。VMD 能将复杂的位移序列进行分解,再通过 LSTM 训练,重构序列从而获取更高的精度。为进一步验证 MVMDLSTM 模型的有效性与可靠性,本文将 VMD 分解后数据作为特征值代入 RNN、ANN 模型以构建 VMDRNN、VMDANN 组合模型,对比三个站不同方向不同组合模型预测效果,以马 13A 为例,不同组合模型预测曲线如图 7 所示。



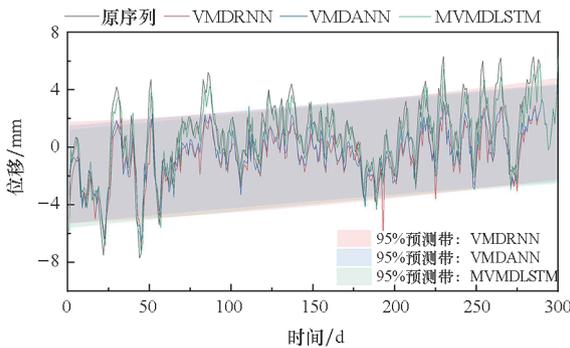
(a) 北方向组合模型预测结果曲线

(a) Prediction result curve of the north direction combination model



(b) 东方向组合模型预测结果曲线

(b) Prediction result curve of the east direction combination model



(c) 垂向组合模型预测结果曲线

(c) Prediction result curve of the up direction combination model

图7 不同VMD组合模型预测结果曲线

Fig.7 Prediction result curve of different VMD combination models

由图7组合模型预测结果曲线可知, MVMDLSTM组合模型三方向预测结果曲线与原序列曲线较为拟合。VMDRNN组合模型结果曲线在三方向上比原序列整体呈现向下偏移的趋势,但在北方向175 d出现增大的情况,可能与站点所在地理环境有关。VMDANN组合模型结果曲线在北方向与垂向上比原序列向下偏移,但在东方向[100 d,300 d]区间内结果曲线比原序列

向上偏移,说明VMDANN模型表现不稳定,预测结果偏差较大。

表4为不同组合模型的评价指标。对比VMDRNN组合模型,采用MVMDLSTM模型对马13A站北方向、东方向、垂向预测结果RMSE值降低了约21%、49%、43%,MAE值降低了约33%、44%、41%;对比VMDANN组合模型,采用MVMDLSTM模型对马13A站北方向、东方向、垂向预测结果RMSE值降低了约20%、48%、60%,MAE值降低了约24%、43%、61%。由此证明了MVMDLSTM模型比VMDRNN、VMDANN组合模型预测效果更好。

表4 不同组合模型的评价指标

Tab.4 Evaluation indicators of different combination models

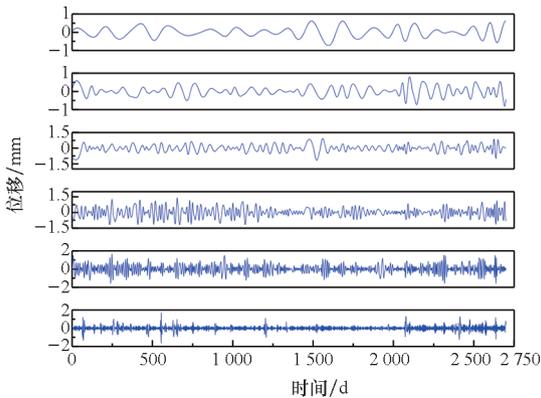
单位:mm

站点	方向	指标	VMDRNN	VMDANN	MVMDLSTM
迎1A	N	RMSE	0.48	0.61	0.35
		MAE	0.38	0.52	0.28
	E	RMSE	0.44	0.49	0.25
		MAE	0.36	0.35	0.21
U	RMSE	1.42	1.65	0.63	
	MAE	1.21	1.41	0.51	
副坝26G	N	RMSE	0.71	0.85	0.35
		MAE	0.55	0.50	0.27
	E	RMSE	0.77	0.65	0.57
		MAE	0.63	0.52	0.44
	U	RMSE	1.35	1.27	0.47
		MAE	1.07	1.00	0.37
马13A	N	RMSE	0.57	0.56	0.45
		MAE	0.48	0.42	0.32
	E	RMSE	0.45	0.44	0.23
		MAE	0.36	0.35	0.20
	U	RMSE	1.29	1.82	0.73
		MAE	1.01	1.55	0.60

综上所述,MVMDLSTM模型在北、东、垂向的RMSE和MAE值均优于VMDRNN与VMDANN组合模型,表明VMD分解有效降低了非平稳非线性序列的预测难度,通过“分解—预测—重构”,MVMDLSTM显著提升了水库位移预测精度,验证了该模型在复杂时序建模中的可靠性。

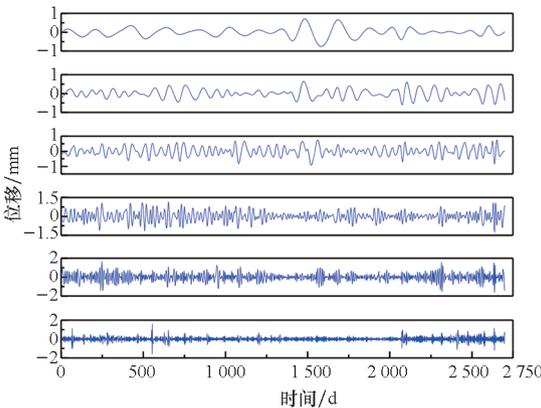
2.2.3 LSTM 组合模型结果分析

EMD 的有效性已经在非线性和非平稳过程的分析中得到了广泛应用,为进一步验证 MVMDLSTM 方法的可靠性,本文构建 EMDLSTM 与 EEMDLSTM 模型,将 EMD 与 EEMD 分解后的 IMF 值代入 LSTM 预测模型中重构。以迎 1A 站北方向为例,EMD 与 EEMD 部分模态分量如图 8 所示,不同组合模型的预测结果曲线分布如图 9 所示。



(a) EMD 方法分解的模态分量

(a) Modal components decomposed by EMD method



(b) EEMD 方法分解的模态分量

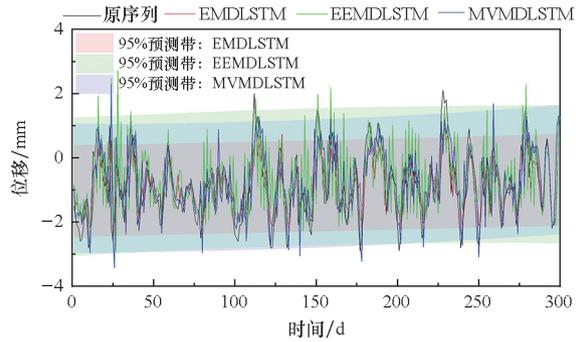
(b) Modal components decomposed by EEMD method

图 8 EMD 与 EEMD 方法分解的模态分量

Fig. 8 Modal components decomposed by EMD and EEMD methods

由图 9 可知, MVMDLSTM 模型的预测曲线更加拟合于原序列。以迎 1A 站为例, EMDLSTM 模型在三方向上结果曲线比原序列向下偏移, 而 EEMDLSTM 模型在北方向与垂向结果曲线比原序列整体向上偏移, 但在东方向上结果拟合曲线向下偏移, 说明模型难以处理非线性时序特征。不同模型预测结果指标评价如表 5 所示。MVMDLSTM 的 RMSE 与 MAE 值均低于 LSTM、EMDLSTM 与 EEMDLSTM 的。在

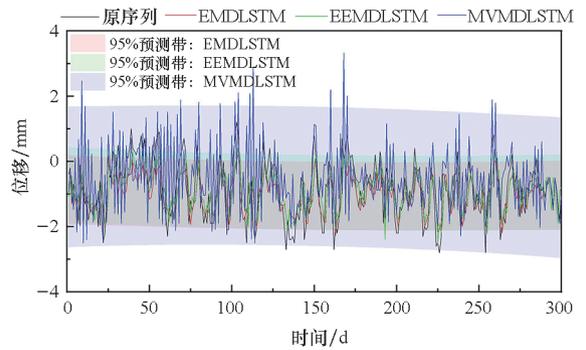
副坝 26G 站的垂向上, EMDLSTM 的 RMSE 甚至达到 3.25 mm, 说明通过 EMD 分解后的特征值经 LSTM 网络训练后导致预测结果偏大, 进一步证明了 MVMDLSTM 模型预测结果的有效性与可靠性。



(a) 北方方向 LSTM 组合模型预测结果曲线

(a) Prediction result curve of the north direction

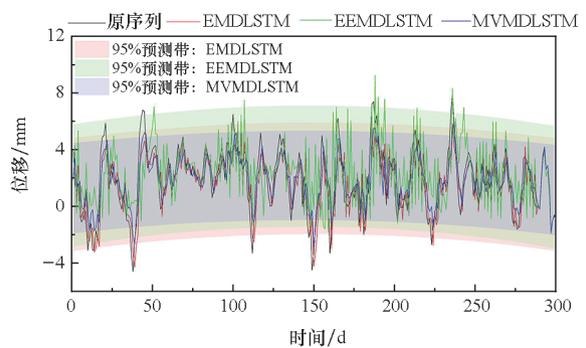
LSTM combination model



(b) 东方向 LSTM 组合模型预测结果曲线

(b) Prediction result curve of the east direction

LSTM combination model



(c) 垂向 LSTM 组合模型预测结果曲线

(c) Prediction result curve of the up direction

LSTM combination model

图 9 不同 LSTM 组合模型预测结果曲线

Fig. 9 Prediction result curve of different LSTM combination models

对比 LSTM 模型, MVMDLSTM 模型的分解与重构能更好地拟合原序列, 预测结果更可靠。以迎 1A 站为例, 图 10 为 LSTM 与 MVMDLSTM 预测

结果曲线,表6为MVMDLSTM相比LSTM的精度指标评价提升度。

表5 顾及LSTM的组合模型评价指标

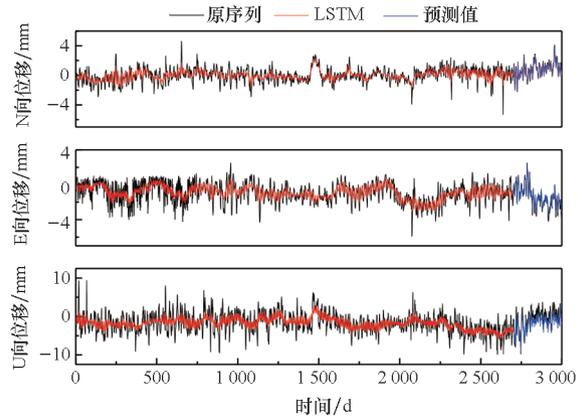
Tab.5 Evaluation indicators of combination model considering LSTM

站点	方向	EMDLSTM	EEMDLSTM	LSTM	MVMDLSTM	
单位:mm						
迎1A	N	RMSE	1.36	1.33	0.53	0.35
		MAE	1.10	1.09	0.41	0.28
迎1A	E	RMSE	2.46	1.85	0.50	0.25
		MAE	2.13	1.59	0.35	0.21
迎1A	U	RMSE	2.99	2.67	1.57	0.63
		MAE	2.14	1.91	1.24	0.51
副坝26G	N	RMSE	1.43	1.38	0.75	0.35
		MAE	1.18	1.16	0.65	0.27
副坝26G	E	RMSE	2.39	1.99	0.66	0.57
		MAE	2.00	1.66	0.53	0.44
副坝26G	U	RMSE	3.25	3.04	1.45	0.47
		MAE	2.64	2.53	1.10	0.37
马13A	N	RMSE	1.42	1.39	0.59	0.45
		MAE	1.22	1.20	0.45	0.32
马13A	E	RMSE	2.61	2.06	0.41	0.23
		MAE	2.41	1.92	0.33	0.20
马13A	U	RMSE	2.91	1.92	1.37	0.73
		MAE	2.35	1.98	1.09	0.60

图10中LSTM与MVMDLSTM模型预测集拟合相比,MVMDLSTM模型在迎1A站北方向、东方向、垂向上的预测结果曲线与原序列拟合效果更好,原序列经分解—重构后预测的数据集更接近于原序列。由表6可得,垂向迎1A站MVMDLSTM模型比LSTM模型预测精度RMSE与MSE值的Q值分别为59.8%、58.9%,其他站在不同方向均有所提升,证明了MVMDLSTM组合模型相比LSTM模型预测的优越性,且具有良好的动态特征。

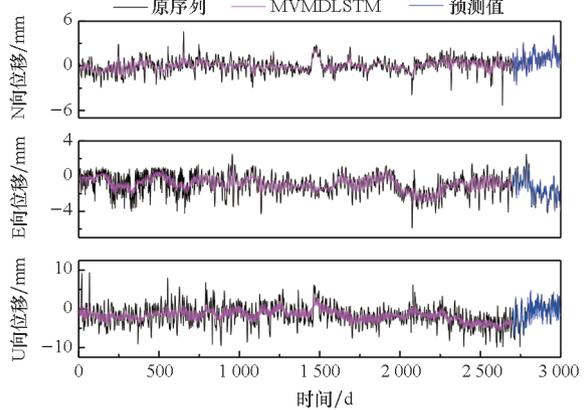
综上所述,本文提出的MVMDLSTM模型不仅解决了VMDLSTM模型中存在的信息泄露等问题,且对LSTM模型中预测结果与原始数据偏差较大问题进行了改正。MVMDLSTM模型相比不同VMD组合模型及LSTM组合模型预测结果较

优,可见该模型具有较强的适应性。



(a) LSTM 预测结果曲线

(a) Prediction result curve of LSTM model



(b) MVMDLSTM 预测结果曲线

(b) Prediction result curve of MVMDLSTM model

图10 LSTM与MVMDLSTM预测结果曲线

Fig.10 Prediction result curve of LSTM and MVMDLSTM

表6 精度指标评价提升度

Tab.6 Precision index evaluation improvement degree

指标	站点	N(Q)	E(Q)	U(Q)
RMSE	迎1A	33.9	50.0	59.8
	副坝26G	55.3	13.6	67.6
	马13A	23.7	43.9	46.7
MAE	迎1A	31.7	40.0	58.9
	副坝26G	58.5	16.9	66.4
	马13A	28.9	39.4	44.9

3 结论

本文通过融合VMD与LSTM算法对非线性非平稳的洋河水库位移形变进行预测,提出了一种混合变分模态长短期记忆网络MVMDLSTM模

型。针对非平稳的洋河水库位移序列,通过引入 VMD 分解改善水库位移时间序列的非线性,构建了 VMDRNN、VMDANN、EMDLSTM、EEMDLSTM 组合模型,且与单一模型 RNN、ANN、LSTM 模型进行对比分析,得出以下结论:

1) 采用单一的 RNN、ANN 与 LSTM 模型会影响预测精度,可能导致预测结果产生偏差。与 RNN、ANN 预测模型相比,LSTM 模型的测试集预测精度更高,证明了 LSTM 模型对非线性非平稳的大坝位移形变时间序列预测的优越性,验证了 MVMDLSTM 组合模型的有效性。

2) 引入 VMD 能将复杂的位移序列进行分解,通过 LSTM 训练后重构序列从而获取更高的精度。VMDRNN 在北方向与垂向上预测曲线比原序列整体向下偏移,VMDANN 在东方向[100 d, 300 d] 区间内结果曲线比原序列向上偏移,MVMDLSTM 组合模型预测结果曲线与原序列曲线较为拟合,说明了 MVMDLSTM 模型预测的有效性。

3) 构建 EMDLSTM 与 EEMDLSTM 模型,将 EMD 与 EEMD 分解后的 IMF 值代入 LSTM 预测模型中重构,组合模型预测的结果评价指标 RMSE 达到 3.25 mm,说明通过 EMD 分解后的特征值经 LSTM 网络训练后导致预测结果偏大,进一步说明了 MVMDLSTM 模型预测结果的可靠性。

4) 相比 LSTM 模型,MVMDLSTM 模型在三方向上预测精度均有提升,在垂向站点预测结果 RMSE 与 MAE 的 Q 值最大分别为 67.6%、66.4%,证明了 MVMDLSTM 模型预测的优越性,为监测位移形变研究提供了可靠的数据资料。

致谢

江西师范大学胡顺强博士在预测模型代码编程工作方面提供了帮助和指导,谨致谢意!

参考文献 (References)

[1] 罗德河,郑东健. 大坝变形的小波分析与 ARMA 预测模型[J]. 水利水运工程学报, 2016(3): 70-75.
LUO D H, ZHENG D J. Wavelet analysis and ARMA prediction model for dam deformation[J]. Hydro-Science and Engineering, 2016(3): 70-75. (in Chinese)

[2] 刘思敏,徐景田,鞠博晓. 基于 EMD 和 RBF 神经网络的大坝形变预测[J]. 测绘通报, 2019(8): 88-91, 95.
LIU S M, XU J T, JU B X. Dam deformation prediction based on EMD and RBF neural network[J]. Bulletin of

Surveying and Mapping, 2019(8): 88-91, 95. (in Chinese)

[3] 王新洲,范千,许承权,等. 基于小波变换和支持向量机的大坝变形预测[J]. 武汉大学学报(信息科学版), 2008, 33(5): 469-471, 507.
WANG X Z, FAN Q, XU C Q, et al. Dam deformation prediction based on wavelet transform and support vector machine[J]. Geomatics and Information Science of Wuhan University, 2008, 33(5): 469-471, 507. (in Chinese)

[4] 郑旭东,陈天伟,王雷,等. 基于 EEMD-PCA-ARIMA 模型的大坝变形预测[J]. 长江科学院院报, 2020, 37(3): 57-63.
ZHENG X D, CHEN T W, WANG L, et al. Dam deformation prediction using EEMD-PCA-ARIMA model[J]. Journal of Yangtze River Scientific Research Institute, 2020, 37(3): 57-63. (in Chinese)

[5] 李桥,巨能攀,黄健,等. 基于 EEMD 与 SE 的 IPSO-LSSVM 模型在坝肩边坡变形预测中的应用[J]. 长江科学院院报, 2019, 36(12): 47-53.
LI Q, JU N P, HUANG J, et al. A prediction method for abutment slope deformation based on IPSO-LSSVM model integrating ensemble empirical mode decomposition and sample entropy[J]. Journal of Yangtze River Scientific Research Institute, 2019, 36(12): 47-53. (in Chinese)

[6] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.

[7] 陈孝文,苏攀,吴彬溶,等. 基于改进长短期记忆网络的时间序列预测研究[J]. 武汉理工大学学报(信息与管理工程版), 2022, 44(3): 487-494, 499.
CHEN X W, SU P, WU B R, et al. Research on time series forecasting based on improved LSTM model[J]. Journal of Wuhan University of Technology (Information & Management Engineering), 2022, 44(3): 487-494, 499. (in Chinese)

[8] 李善寿,马泉杰,潘璐茜,等. 基于 VMD 和 LSTM-CNN 的短期负荷预测模型研究[J]. 控制工程, 2023, 30(3): 469-478.
LI S S, MA X J, PAN L X, et al. Research on short-term load forecasting model based on VMD and LSTM-CNN[J]. Control Engineering of China, 2023, 30(3): 469-478. (in Chinese)

[9] 胡向阳,孙宪坤,尹玲,等. 基于多变量 LSTM 的 GPS 坐标时间序列预测模型[J]. 传感器与微系统, 2021, 40(3): 40-43.
HU X Y, SUN X K, YIN L, et al. GPS coordinate time series prediction model based on multivariable LSTM[J]. Transducer and Microsystem Technologies, 2021, 40(3): 40-43. (in Chinese)

[10] 戴邵武,陈强强,刘志豪,等. 基于 EMD-LSTM 的时间序列预测方法[J]. 深圳大学学报(理工版), 2020, 37(3): 265-270.
DAI S W, CHEN Q Q, LIU Z H, et al. Time series prediction based on EMD-LSTM model[J]. Journal of

- Shenzhen University (Science and Engineering), 2020, 37(3): 265 – 270. (in Chinese)
- [11] 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): 34 – 42.
CHEN Z A, XIONG X, YOU Y Y. Variational mode decomposition and long short time neural network for dam deformation prediction [J]. Science of Surveying and Mapping, 2021, 46(9): 34 – 42. (in Chinese)
- [12] HUMPHREY W, DALKE A, SCHULTEN K. VMD: visual molecular dynamics [J]. Journal of Molecular Graphics, 1996, 14(1): 33 – 38.
- [13] JIN Z H, CHEN G D, YANG Z X. Rolling bearing fault diagnosis based on WOA-VMD-MPE and MPSO-LSSVM[J]. Entropy (Basel), 2022, 24(7): 927.
- [14] HUANG Z K, HOU Z N, HUANG J H, et al. A new adaptive WVS based denoising method on GNSS vertical time series [J]. Acta Geodynamica et Geomaterialia, 2023, 20(2): 71 – 82.
- [15] 高结旺. 基于 ANN-LSTM 混合预测方法的边坡滑坡预警系统研究[D]. 赣州: 江西理工大学, 2022.
GAO J W. Research on early warning system of slope and landslide based on ANN-LSTM hybrid prediction method[D]. Ganzhou: Jiangxi University of Science and Technology, 2022. (in Chinese)
- [16] 郭佳丽,邢双云,栾昊,等. 基于改进的 LSTM 算法的时间序列流量预测[J]. 南京信息工程大学学报(自然科学版), 2021, 13(5): 571 – 575.
GUO J L, XING S Y, LUAN H, et al. Prediction of time series traffic based on improved LSTM algorithm[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2021, 13(5): 571 – 575. (in Chinese)
- [17] WANG J, JIANG W P, LI Z, et al. A new multi-scale sliding window LSTM framework (MSSW-LSTM): a case study for GNSS time-series prediction [J]. Remote Sensing, 2021, 13(16): 3328.
- [18] LI Z, LU T D, HE X X, et al. An improved cyclic multi model-extreme gradient boosting (CMM-XGBoost) forecasting algorithm on the GNSS vertical time series [J]. Advances in Space Research, 2023, 71(1): 912 – 935.
- [19] QIAN Z, PEI Y, ZAREIPOUR H, et al. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications [J]. Applied Energy, 2019, 235: 939 – 953.
- [20] WANG Y M, WU L. On practical challenges of decomposition-based hybrid forecasting algorithms for wind speed and solar irradiation [J]. Energy, 2016, 112: 208 – 220.