

DOI: 10.3876/j.issn.1000-1980.2025.02.001

基于调和分析及 VMD-LSTM 混合模型的甬江河口水位预报方法

陈永平^{1,2}, 韩韬^{1,2}, 邱超³, 甘敏⁴, 谭亚^{1,2}, 王瑾琪^{1,2}

(1. 河海大学水灾害防御全国重点实验室, 江苏南京 210098; 2. 河海大学港口海岸与近海工程学院, 江苏南京 210098;
3. 浙江省水文管理中心, 浙江杭州 310009; 4. 中国科学院南京地理与湖泊研究所, 江苏南京 210008)

摘要: 为解决甬江感潮河段潮位预报总体精度偏低的问题, 构建了一种基于经典调和分析(T_TIDE)、变分模态分解(VMD)和长短时记忆神经网络(LSTM)的混合模型(VMD-LSTM混合模型)。VMD-LSTM混合模型采用T_TIDE程序包对甬江河口逐时水位数据进行回报(即潮位), 用实测水位减去潮位得到相应余水位, 并采用VMD模型将余水位分解为13个本征模函数(IMF), 依次对应D0~D12潮族, 采用LSTM模型分别训练余水位的各个IMF分量和潮位并分别向后预报12~48 h, 各个IMF分量和潮位的预报值之和即为河口水位的预测值。结果表明: VMD模型可对甬江河口余水位中D0~D12潮族波动进行完全分离; VMD-LSTM混合模型12、24、36、48 h短期水位预报的均方根误差(RMSE)比LSTM模型最多分别降低了0.15、0.13、0.16、0.16 m; VMD-LSTM混合模型在D0、D2潮族频带的误差修正最明显, 相比LSTM模型, 可分别将D0、D2潮族的谱峰预报误差最多降低0.05、0.04 m·d^{0.5}。

关键词: 甬江口; 河口潮汐; 变分模态分解; LSTM模型; 调和分析; 水位预报

中图分类号:P338 **文献标志码:**A **文章编号:**1000-1980(2025)02-0001-10

Water level forecasting method for the Yongjiang River Estuary based on harmonic analysis and VMD-LSTM hybrid model

CHEN Yongping^{1,2}, HAN Tao^{1,2}, QIU Chao³, GAN Min⁴, TAN Ya^{1,2}, WANG Jinqi^{1,2}

(1. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China;
2. College of Harbour, Coastal and Offshore Engineering, Hohai University, Nanjing 210098, China;
3. Hydrological Management Center of Zhejiang Province, Hangzhou 310009, China;
4. State Key Laboratory of Lake Science and Environment, Nanjing Institute of Geography and Limnology,
Chinese Academy of Sciences, Nanjing 210008, China)

Abstract: To address the challenge of achieving high accuracy in tidal level forecasting along the tidal reach of the Yongjiang River Estuary, this study introduces a hybrid model (VMD-LSTM hybrid model) that integrates classical harmonic analysis (T_TIDE), variational mode decomposition (VMD), and long short-term memory network (LSTM). The VMD-LSTM hybrid model utilizes the T_TIDE package to obtain the hourly water level data of the estuary. The tide-simulated water levels are calculated, and the corresponding residual water levels are derived by subtracting tidal levels from the measured data at each station. The VMD model is employed to decompose the residual water levels into 13 Intrinsic Mode Functions (IMFs), specifically IMF₀ through IMF₁₂, which correspond to the D0 to D12 tidal species in sequence. LSTM-based regression is performed on each IMF component and tide level of the residual water levels for step-by-step prediction over a forecast horizon ranging from 12 to 48 hours. The sum of the predicted values of each IMF component and tide level is the predicted value of the estuarine water level. The results showed that: the VMD model can completely separate the D0 to D12 tidal constituent fluctuations in the residual water level for the Yongjiang River Estuary; the root mean square

基金项目: 国家重点研发计划项目(2023YFC3008100); 浙江省水利科技重大项目(RA2202)

作者简介: 陈永平(1976—), 男, 教授, 博士, 主要从事河口海岸水环境研究。E-mail:ypchen@hhu.edu.cn

通信作者: 韩韬(2001—), 男, 硕士研究生, 主要从事河口海岸水动力过程研究。E-mail:2466598292@qq.com

引用本文: 陈永平, 韩韬, 邱超, 等. 基于调和分析及 VMD-LSTM 混合模型的甬江河口水位预报方法[J]. 河海大学学报(自然科学版), 2025, 53(2): 1-10.

CHEN Yongping, HAN Tao, QIU Chao, et al. Water level forecasting method for the Yongjiang River Estuary based on harmonic analysis and VMD-LSTM hybrid model[J]. Journal of Hohai University(Natural Sciences), 2025, 53(2): 1-10.

error (RMSE) of the VMD-LSTM hybrid model for short-term water level forecasting at 12 hours, 24 hours, 36 hours, and 48 hours was reduced by at most 0.15, 0.13, 0.16, and 0.16 m, respectively, compared to the LSTM model. In addition, the hybrid model of VMD-LSTM demonstrates the most significant capability for error correction in the D0 and D2 tidal bands. Compared to the LSTM model, this approach can reduce the spectral peak prediction errors of these tidal bands by up to 0.05, 0.04 $m \cdot d^{0.5}$, respectively.

Key words: the Yongjiang River Estuary; estuarine tides; variational mode decomposition; LSTM model; harmonic analysis; water level forecasting

准确的河口水位预报对于区域洪水预警、航运安全、生态环境保护和人们的生产生活等具有重要意义。在忽略观测误差的情况下,河口水位可视为潮位与余水位之和^[1]。潮位是由潮汐引起的,潮汐的形成与月球、太阳对地球上海水的引潮力相关,因此潮位有着较为规律的波动特征,而余水位作为水位去除掉周期性潮汐之后余留的部分,主要由径流、风和口外陆架环流产生^[2],具有复杂的时空变化特征。当海洋潮波传播至河口并上溯时,其与径流、河道地形等非天文因素产生非线性相互作用^[3-4],使得河口潮汐分潮振幅和迟角等参数随时间变化,呈现出非稳态特点^[5],因此河口地区的水位预报难点主要来源于余水位的非确定性和时变性^[6]。

基于预报目的的差异性,有不同的方法被用于预报河口潮汐,经典调和分析方法(classical harmonic analysis)是最基本的方法之一^[7]。经典调和分析方法假设潮汐分潮调和常数为恒定值,但潮波在河道中传播时会受径流等非天文因素影响,分潮调和常数在受到径流摩擦耗散作用后会随时间变化,这与其假设相悖,因此该方法在受径流影响较为显著的感潮河段上游段的预报效果欠佳^[5,8]。为了考虑径流对潮汐的影响,Matte 等^[5]基于 Kukulka 等^[9]的径潮相互作用理论框架,在 T_TIDE 模型^[7]中将河口上游径流量和口门附近潮差作为输入参数,将非平稳的外力强迫直接引入调和分析基础函数中,给出了专门用于分析河口潮汐的非稳态调和分析(nonstationary tidal harmonic analysis, NS_TIDE)模型,该模型在常年受径流影响显著的大型河口(如美国哥伦比亚河^[10]、加拿大圣劳伦斯河^[11]、中国长江^[12]和珠江^[13])水位预报中得到广泛应用。但该模型对以潮为主,径流在特定时间段有较大影响的中小型河口并不适用,针对此类河口的水位预报有待进一步研究。

随着人工智能的快速发展,以决策树回归、随机森林回归、神经网络回归及支持向量回归为代表的机器学习算法被广泛应用于各种非平稳时间序列的预报中。长短期记忆神经网络(long short term memory, LSTM)具有能有效解决梯度消失问题、捕捉序列数据中的长期依赖关系等优点^[14-16],已成为湖泊、河流水位、径流量等水文预报领域中的流行算法^[17-20]。例如,郭燕等^[21]采用 LSTM 模型预测了鄱阳湖的水位变化;蒋晨凯等^[22]采用 LSTM 模型构建了秦淮河东山站 1~6 d 预见期的日平均水位预报模型。然而余水位来源复杂,波动紊乱,若将其作为整体来研究会忽略不同成因所导致的变化规律^[23],将其直接作为机器学习模型的输入也不易捕捉到不同信号的非平稳特征和变化趋势,从而对总水位预报精度产生不利影响。

经验模态分解(empirical mode decomposition, EMD)基于瞬时频率、本征模态函数(intrinsic mode function, IMF)的概念^[24],能够将复杂信号分解为若干个 IMF 分量,每个 IMF 分量表征信号的局部特征。Pan 等^[25]首次将 EMD 引入河口潮汐领域,得出美国哥伦比亚河口潮族振幅具有显著的季节性和半月周期变化的结论;王亦斌等^[26]将 EMD 和机器学习模型相结合,预测了南水北调工程中某河流的水位。然而使用 EMD 方法对复杂非平稳信号进行分解时易产生端点效应和模态混叠问题^[27]。变分模态分解(variational mode decomposition, VMD)相较于 EMD 具有较好抗噪能力,能有效解决这一问题^[28]。Gan 等^[29]采用 VMD 模型将美国哥伦比亚河 Longview 测站的水位分解为 12 个模态,避免了 EMD 模型分解信号时出现的模态混叠问题;此后,Gan 等^[30]又将 VMD 模型应用于长江口,首次实现长江口潮族水位的完全分离,并分析了长江河口潮族水位的非稳态特征。

目前 VMD 模型在河流水质^[31]、降水量^[32]、水库水位^[33]、风电功率^[34]预测等领域已得到广泛应用,但在河口水位预测方面还少有报道。本文构建了 VMD-LSTM 混合模型,先将河口水位分离为潮位和余水位,再对余水位数据进行分解,并通过 LSTM 模型进行学习训练和预测,提升了河口水位的预报精度。

1 研究区域与数据

宁波甬江位于浙江东部沿海、杭州湾之南,姚江和奉化江是其主要支流。其中,姚江从西南方向流入,奉

化江从北方流入,三者在宁波市附近汇合后形成甬江,经镇海口注入东海^[35]。由表1可知,甬江口各水文站潮型指数(K1和O1分潮振幅之和除以M2分潮振幅)在0.51~0.68之间,属不规则半日潮;受河床阻力和径流顶托作用等因素影响,潮波在向上游传播时能量逐渐耗损,致使K1、O1、M2、S2等主要分潮振幅自镇海口站向上游逐渐衰减。同时,分潮迟角均沿上游增加,反映了潮波信号沿上游传播时的延迟;平均潮位、平均潮差分别自镇海口站向上游逐渐增大、减小;甬江河口潮汐不对称特征以涨潮占优为主,仅口门附近的镇海口、镇海站存在小段落潮占优区;甬江口为潮控小型河口,全年径流量相对较小,河道水位主要受外海潮汐驱动,此外还受到径流、台风、降水等多重水动力要素影响。各水文站位置如图1所示,研究资料为各水文站2018—2021年逐时水位数据,图2为各水文站逐时水位过程曲线。

表1 甬江口各水文站主要分潮调和常数及潮汐特征值

Table 1 Main tidal harmonic constants and tidal characteristic values at each station along the Yongjiang River Estuary

水文站	分潮振幅/cm				分潮迟角/(°)				平均潮位/m	平均潮差/m	平均历时/h	
	K1	O1	M2	S2	K1	O1	M2	S2			涨潮	落潮
镇海口	31.35	20.55	100.94	37.25	214.7	171.0	321.9	2.7	0.12	2.82	6.26	6.16
镇海	30.70	20.27	99.64	36.43	216.3	172.3	324.9	6.3	0.45	2.77	6.23	6.19
宁波	25.43	18.54	81.40	28.00	235.0	185.2	353.3	34.6	0.59	2.39	5.47	6.94
澄浪堰	24.56	18.01	75.71	25.88	238.8	188.6	358.1	39.6	0.61	2.26	5.42	6.99
北渡	20.51	15.48	53.19	16.03	266.5	213.9	45.9	89.4	0.73	1.65	5.29	7.09

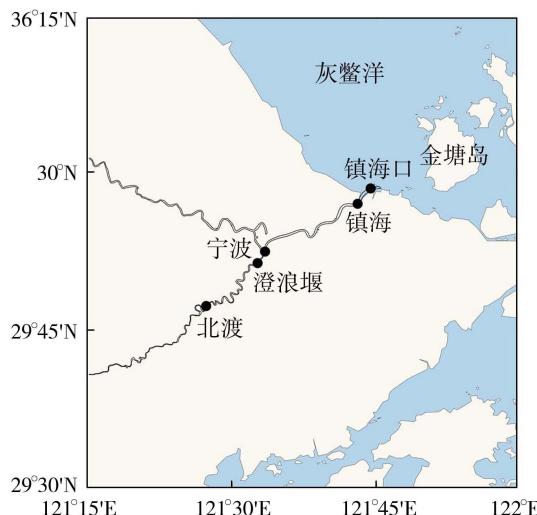


图1 甬江口各水文站位置示意图

Fig. 1 Map of the Yongjiang River Estuary and locations of each hydrometric station

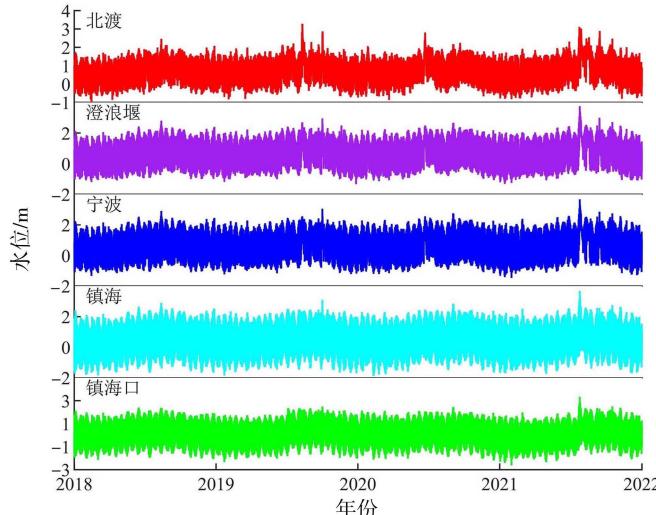


图2 甬江口各水文站水位实测数据

Fig. 2 Measured data of water levels at each station along the Yongjiang River Estuary

2 研究方法

本文首先采用经典调和分析方法对甬江河口各水文站逐时水位进行回报,在忽略观测误差的前提下,回报水位即为潮位,余水位即为实测水位与潮位之差;然后采用VMD模型对来源复杂的余水位序列进行分解以获得有限个IMF分量;最后采用LSTM模型分别训练余水位的各个IMF分量和潮位并分别向后预报12~48 h,各个IMF分量和潮位的预测值之和即为水位预测值,其具体分析流程如图3所示。图3中, $\{u_k\}$ 表示第k个模态分量的信号; $\{w_k\}$ 为第k个模态的中心频率;n为当前迭代的次数;K为总的模态数;E为当前模态的误差; ϵ 为设定的收敛阈值;IMF₁、IMF₂、…、IMF_k为通过VMD分解余水位得到的k个模态分量;F为通过LSTM模型预测的潮水位; P_1 、 P_2 、…、 P_k 为LSTM模型对于VMD分解后的k个模态分量的预报值;P为最终预报值; x'_1 、 x'_2 、…、 x'_t 分别为从时间步1到t的输入数据时间序列;LSTM₁、LSTM₂、…、LSTM_f分别为LSTM网络中第1层到第f层的长短期记忆单元;f为LSTM层数; h'_1 、 h'_2 、…、 h'_t 分别为从时间步1到t的输出数据时间序列。

2.1 调和分析方法

在调和分析的框架下,潮位被表示为各个分潮对应的三角函数之和:

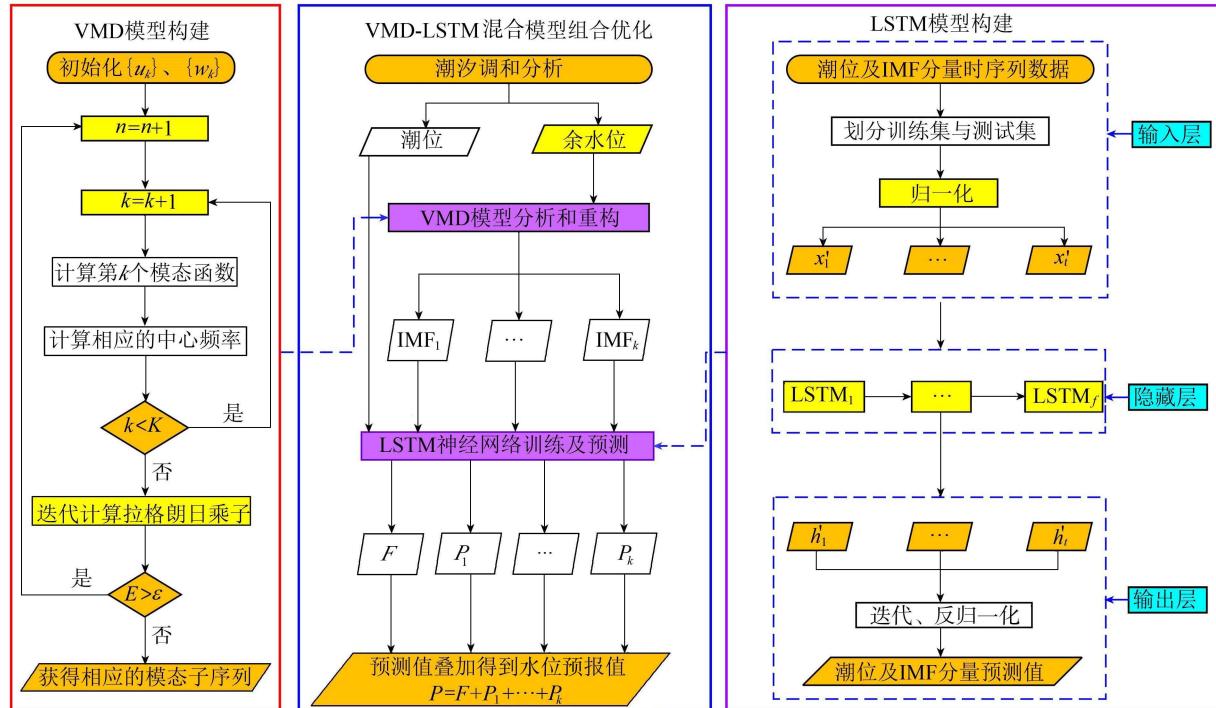


图 3 分析流程图

Fig. 3 Flow chart of analysis

$$Z = S_0 + \sum_{j=1}^J H_j \cos(\sigma_j t - g_j) \quad (1)$$

式中: Z 为潮位; t 为时刻; S_0 为平均海平面; J 为分潮数; H_j 、 σ_j 、 g_j 分别为第 j 个分潮的振幅、角速度和迟角。

潮位个数通常会多于式(1)中未知参数的个数, 所以式(1)属于超定方程, 它的求解方法为最小二乘法或者迭代重加权最小二乘法^[8]。

2.2 VMD 模型

变分模态分解模型是一种从频域空间分解信号的模型, 在经验模态分解的基础上改进而来^[28]。该模型通过优化各模态分量的带宽估计过程以解决约束变分问题, 最终得到最优解。首先, 通过在线性约束问题中引入惩罚因子 α 和拉格朗日乘子 λ 将其转换为非线性约束问题; 然后采用交替方向乘子法迭代更新模态函数、中心频率和拉格朗日乘子, 可得到信号分解的所有模态。

2.3 LSTM 模型

LSTM 模型是一种特殊的循环神经网络, 由多个记忆单元结构组成, 每个记忆单元分别由遗忘门、输入门、输出门控制^[14,36]。LSTM 单元结构如图 4 所示, 图中 f_t 、 i_t 、 o_t 分别为输入门、遗忘门和输出门的激活值, x_t 为当前时刻的输入信息, \tilde{C}_t 为当前时刻的候选记忆单元状态, h_t 、 h_{t-1} 分别为当前时刻、上一时刻的输出信息, σ 为 Sigmoid 函数, C_t 、 C_{t-1} 分别为当前时刻、上一时刻的记忆单元状态。

3 结果与分析

3.1 调和分析

采用 T_TIDE 程序包对甬江河口各水文站水位数据进行调和分析, 得到各水文站潮位及余水位(图 5): 潮位波动稳定, 各水文站潮位变化趋势一致。受季风影响, 甬江流域 4—9 月为丰水期^[37], 径流量相对较大, 且夏季易受西北太平洋台风影响, 风暴潮天气下甬江流域短期内出现强降雨, 河流流量会在未来几天出现较强波动, 各水文站余水位的变化规律与之大致相同。

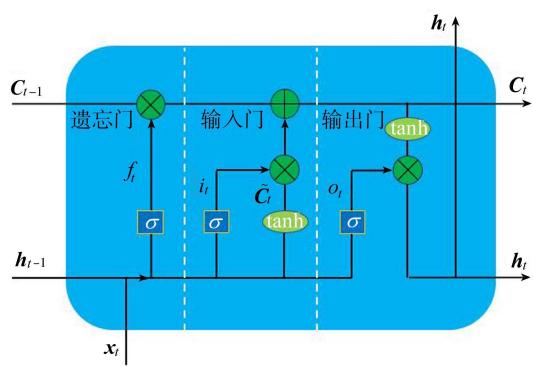


图 4 LSTM 单元结构图

Fig. 4 Structure diagram of LSTM unit

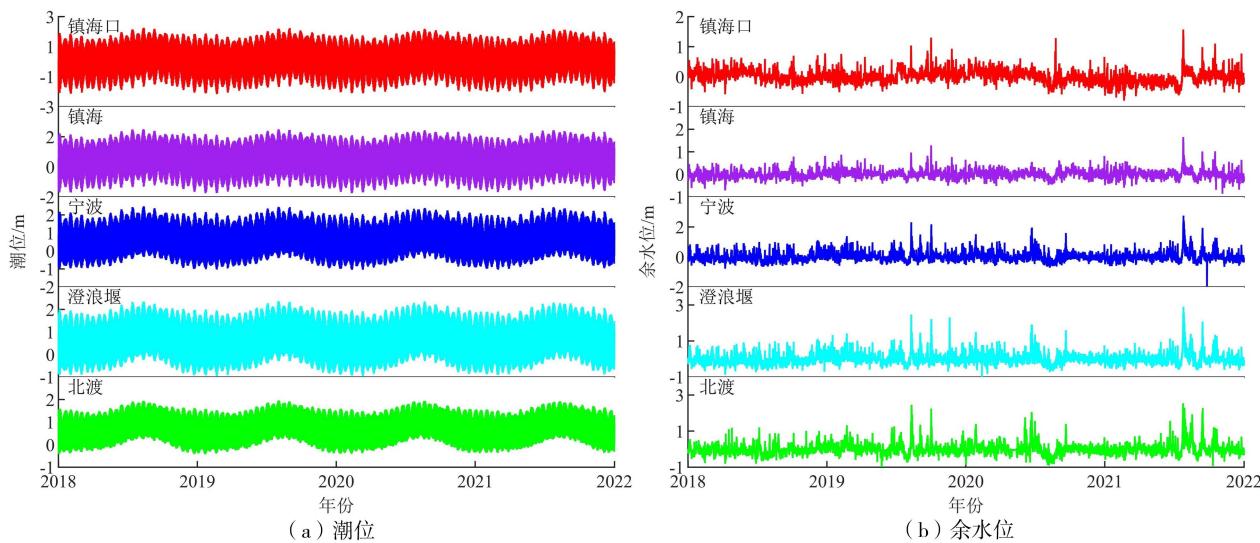


图 5 甬江口各水文站潮位和余水位

Fig. 5 Tidal levels and residual water levels at each station along the Yongjiang River Estuary

3.2 IMF 分量分析

VMD 模型的主要建模参数包括判别精度、噪声容限、惩罚因子和分解尺度。模型结果受判别精度的影响不大,本文将其设置为 10^{-7} ^[28]。噪声容限和惩罚因子的取值会影响 VMD 模型对信号的分离效果和对信号分解的平滑程度。经过大量数值试验,本文最终将噪声容限取 0.1, 惩罚因子取 2 000。分解尺度即 IMF 分量的个数与潮族数量有关^[30], 河口潮汐包含 D0 ~ D12 潮族的频率波动, 每个潮族的频率区间互不重合, 因此本文将分解尺度设置为 13。

以宁波站为例,采用 VMD 模型对余水位数据进行分解,得到 13 个 IMF 分量的平均周期和平均振幅(表 2):不同时间尺度下的潮汐波动被严格划分为不同的模态,所有潮族之间完全分离, $IMF_1 \sim IMF_{13}$ 分量都仅包含 D0 ~ D12 潮族的能量,不存在模态混叠问题。 IMF_1 分量的平均振幅最高, $IMF_{10} \sim IMF_{13}$ 分量平均振幅较小, IMF_3 分量在 $IMF_2 \sim IMF_{13}$ 分量中平均振幅最大,与甬江河口半日潮族水位贡献突出的物理背景保持一致。

3.3 LSTM 模型模拟结果

3.3.1 评估指标及数据划分

本文采用均方根误差(RMSE)和决定系数(R^2)评估水位的预测精度。选取 T_TIDE 模型分离的潮位和 VMD 模型分解余水位获得的 13 个 IMF 分量在 2018—2021 年的时序数据(共 $35\ 064 \times 14$ 个)用于模型试验,其中 2018—2020 年的时序数据(共 $26\ 304 \times 14$ 个)用于 LSTM 模型训练,2021 年的时序数据(共 $8\ 760 \times 14$ 个)作为验证集,测试模型性能。考虑到 2018—2020 年的时序数据中训练集与验证集数据比例的不同可能会对试验精度产生影响,本文采取 3 组常用的训练集占比对宁波站进行试验。由表 3 可知,选取 70% 时序数据作为训练集,剩余 30% 数据用作验证集时 RMSE 最小, R^2 最大, 模型性能达到最优,因此本文将训练集和验证集的比例设定为 7 : 3。

3.3.2 超参数选取

输入数据长度是影响 LSTM 模型预测精度最重要的超参数之一。考虑到不同输入数据长度会对不同预报时长(L)的水位精度产生影响,本文将输入数据长度按 6 h 递增的顺序从 6 h 依次递增到 48 h, 分别对预报

表 2 宁波站各 IMF 分量的特征参数

Table 2 Characteristic parameters of IMFs at Ningbo station

IMF 分量	平均周期/d	平均振幅/m	隶属潮族
1	13.617	0.222	D0
2	1.176	0.073	D1
3	0.521	0.104	D2
4	0.358	0.037	D3
5	0.262	0.031	D4
6	0.208	0.024	D5
7	0.172	0.025	D6
8	0.148	0.012	D7
9	0.128	0.021	D8
10	0.115	0.008	D9
11	0.103	0.009	D10
12	0.094	0.006	D11
13	0.086	0.010	D12

表 3 训练集占比不同时对应的 LSTM 模型预报精度

Table 3 LSTM model prediction accuracy corresponding to different training set proportions

预报时长/h	RMSE/m			R^2		
	训练集占比 60%	训练集占比 70%	训练集占比 80%	训练集占比 60%	训练集占比 70%	训练集占比 80%
12	0.156	0.150	0.152	0.978	0.981	0.976
24	0.172	0.165	0.169	0.957	0.968	0.956
36	0.209	0.201	0.209	0.918	0.935	0.907
48	0.223	0.219	0.238	0.909	0.916	0.895

未来 12、24、36、48 h 的水位进行 4×6 组训练。训练结果(图 6)表明:对于同一输入数据长度,随着预报时长的增加,均方根误差增加,决定系数降低;对于同一预报时长而言,随着输入数据长度变长,均方根误差先快速减小,后趋于平稳不再显著减小,最终 RMSE 均低于 0.2 m。决定系数先快速增大后也趋于平稳不再显著增大,最终 R^2 均高于 0.9。为了提升模型计算效率,本文在预报未来 12、24、36、48 h 水位时,输入数据长度分别取 18、24、36、36 h。

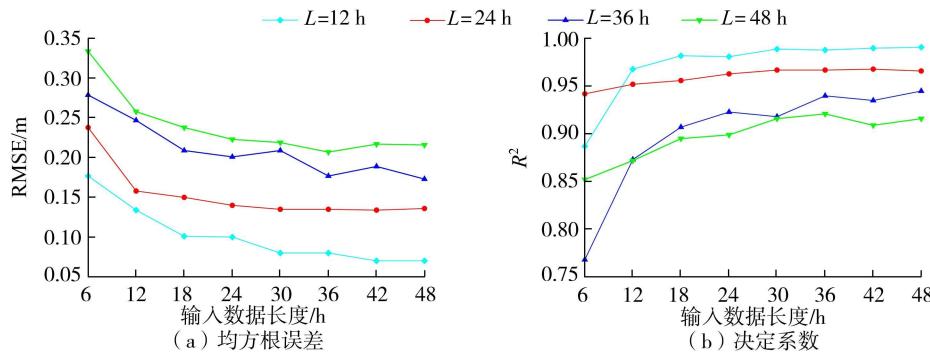


图 6 不同输入数据长度条件下的均方根误差和决定系数

Fig. 6 Root mean square error and R -Square under different input data length conditions

本文构建的 LSTM 模型选择 Tanh 为激活函数、Adam 为优化算法^[28], 输入层、隐藏层及输出层均选取为 1 个, 采用验证集上的 RMSE 作为评估指标选取隐藏层中 LSTM 层数、神经元个数、丢弃率、批尺寸和迭代次数等其他超参数的最优配置。经过多次学习训练, LSTM 模型的超参数取值见表 4。

3.3.3 LSTM 模型预测结果

T_TIDE 模型预报短期水位时, 参数未发生变化, 它的预报精度不会随预报时长变化, 因此在统计 T_TIDE 模型预报精度时, 表 5 都只列出了一个值。由表 5 可知, VMD-LSTM 混合模型的预报精度显著高于 LSTM 模型。以 24 h 逐时水位预报为例, VMD-LSTM 混合模型在沿江各站的 RMSE 范围为 0.10~0.16 m, R^2 范围为 0.94~0.99, ± 0.30 m 合格率范围为 94.9%~99.0%; 而 LSTM 模型对应的 RMSE 范围为 0.21~0.27 m, R^2 范围为 0.78~0.93, ± 0.30 m 合格率范围为 82.4%~88.3%。VMD-LSTM 混合模型做 48 h 逐时预报时, 其 RMSE 也不超过 0.22 m, R^2 不低于 0.9, ± 0.30 m 合格率也能保证在 90% 左右, VMD 模型的加入能够将 LSTM 模型在各水文站的短期(48 h 内)逐时预报 RMSE 减少 0.09~0.16 m, R^2 增加 0.04~0.45, ± 0.30 m 合格率提升 8.8%~21.8%。

由图 7 可知, VMD-LSTM 混合模型在所有水文站的预报值整体上都比 LSTM 模型更贴近 45°线(最佳拟合曲线), 这表明 VMD-LSTM 混合模型的预报性能整体上优于 LSTM 模型, 说明 VMD 模型对余水位的分解能够较好地提升各水文站的水位预报精度。由于本文暂未考虑上游径流等因素对水位预报精度的影响, 而河道上游受径流影响要强于下游, 下游潮位主要受外海潮汐控制, 潮位变化规律与外海潮汐更为相似, 所以对下游站点水位的预报效果更优。

表 4 LSTM 模型最优超参数取值

Table 4 Optimal hyperparameter values of LSTM

L/h	LSTM 层数	神经元个数	丢弃率	批尺寸	迭代次数
12	2	64	0.1	8	50
24	2	32	0.1	16	50
36	2	128	0.1	8	50
48	2	32	0.1	16	50

注: LSTM 层数、神经元个数、丢弃率、批尺寸、迭代次数的寻优范围分别为 >1~<4, >2~<512, >0~<0.2, >8~<32, >10~<100。

表 5 各模型预测精确度对比

Table 5 Comparison of prediction accuracy of each model

水文站	T_TIDE 模型	RMSE/m				LSTM 模型				R^2			
		VMD-LSTM 混合模型				LSTM 模型				VMD-LSTM 混合模型			
		$L=12\text{ h}$	$L=24\text{ h}$	$L=36\text{ h}$	$L=48\text{ h}$	$L=12\text{ h}$	$L=24\text{ h}$	$L=36\text{ h}$	$L=48\text{ h}$	$L=12\text{ h}$	$L=24\text{ h}$	$L=36\text{ h}$	$L=48\text{ h}$
镇海口	0.22	0.09	0.10	0.16	0.19	0.23	0.23	0.25	0.25	0.99	0.99	0.97	0.95
镇海	0.24	0.11	0.12	0.15	0.15	0.21	0.21	0.24	0.25	0.98	0.98	0.97	0.97
宁波	0.35	0.14	0.15	0.19	0.22	0.25	0.26	0.34	0.35	0.97	0.97	0.94	0.92
澄浪堰	0.36	0.09	0.16	0.16	0.21	0.23	0.26	0.32	0.36	0.99	0.95	0.95	0.92
北渡	0.37	0.08	0.15	0.19	0.20	0.23	0.27	0.33	0.36	0.98	0.94	0.91	0.90
R^2													
$\pm 0.30\text{ m}$ 合格率/%													
水文站	LSTM 模型				T_TIDE 模型	VMD-LSTM 混合模型				LSTM 模型			
	$L=12\text{ h}$	$L=24\text{ h}$	$L=36\text{ h}$	$L=48\text{ h}$		$L=12\text{ h}$	$L=24\text{ h}$	$L=36\text{ h}$	$L=48\text{ h}$	$L=12\text{ h}$	$L=24\text{ h}$	$L=36\text{ h}$	$L=48\text{ h}$
镇海口	0.93	0.93	0.92	0.92	87.6	99.2	99.0	96.2	95.1	86.0	84.2	83.4	81.7
镇海	0.94	0.93	0.92	0.91	85.5	99.1	98.0	96.9	94.7	89.2	88.3	84.7	83.3
宁波	0.90	0.87	0.77	0.76	77.9	97.9	95.2	92.3	88.7	84.7	83.4	70.5	70.3
澄浪堰	0.89	0.79	0.76	0.73	76.3	99.6	95.5	94.2	89.8	85.5	82.5	75.7	74.7
北渡	0.83	0.78	0.65	0.55	74.8	99.4	94.9	92.9	92.2	86.8	82.4	74.9	72.4

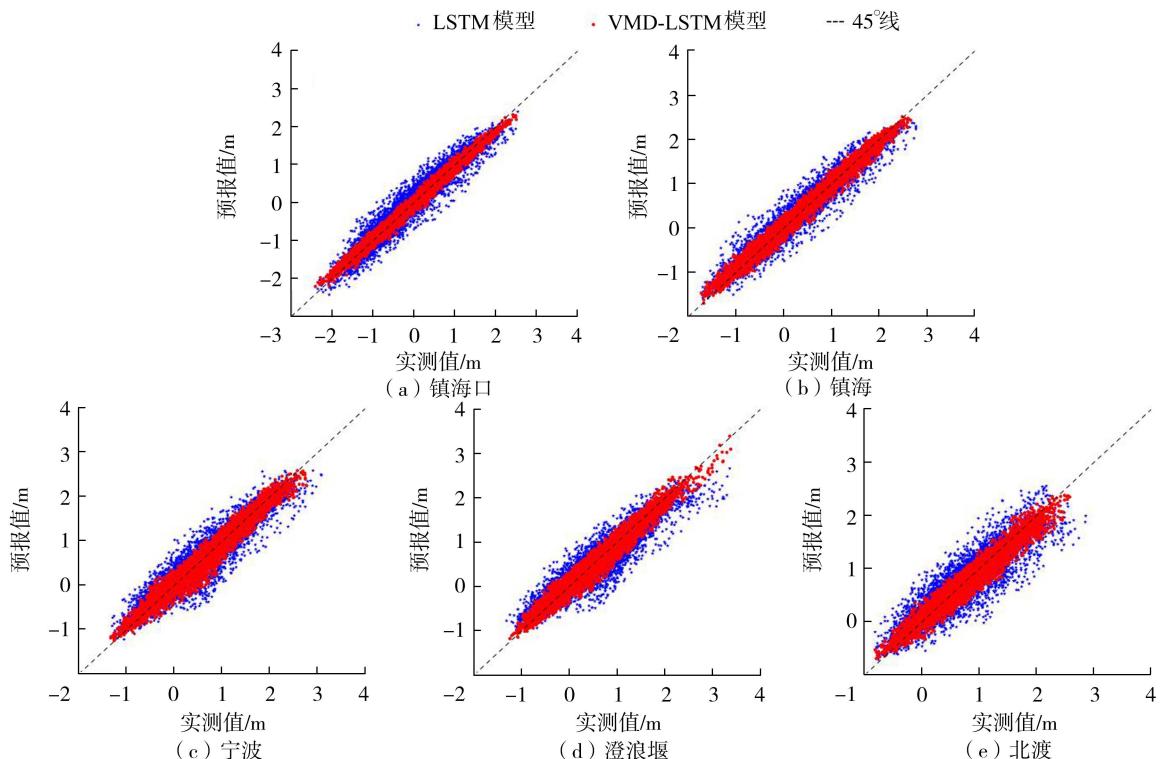


图 7 甬江口各水文站的 24 h 逐时水位预报值与实测值对比

Fig. 7 Comparison of the 24 h water-level prediction results with the measurements at each station in the Yongjiang River Estuary

4 讨 论

为明确 VMD-LSTM 混合模型对甬江口各水文站各潮族频带的改进效果,对 VMD-LSTM 混合模型的预报误差作谱分析,并将其与 LSTM 模型的预报误差谱作对比。由图 8 可知,LSTM 模型在 D0、D2 潮族频带的误差比其他潮族频带大,而 VMD-LSTM 混合模型在各个潮族频带的预报误差较为平稳且能量都低于 LSTM 模型。LSTM 模型误差谱在 D0、D2 潮族频带的谱峰范围分别为 $0.04 \sim 0.06$ 、 $0.04 \sim 0.07 \text{ m} \cdot \text{d}^{0.5}$,而 VMD-LSTM 混合模型误差在 D0、D2 的谱峰分别不超过 0.02 、 $0.03 \text{ m} \cdot \text{d}^{0.5}$ 。VMD-LSTM 混合模型在 D1、D4、D6 等主要潮族的预报结果也比 LSTM 模型要更好一些。VMD-LSTM 混合模型在 D0、D2 潮族频带的预报结果最好,可将 D0、D2 潮族的谱峰预报误差分别降低 $0.02 \sim 0.05$ 、 $0.02 \sim 0.04 \text{ m} \cdot \text{d}^{0.5}$ 。因此,图 8 从频谱的角度证

实了 VMD-LSTM 混合模型比 LSTM 模型具有更高的预报精度。

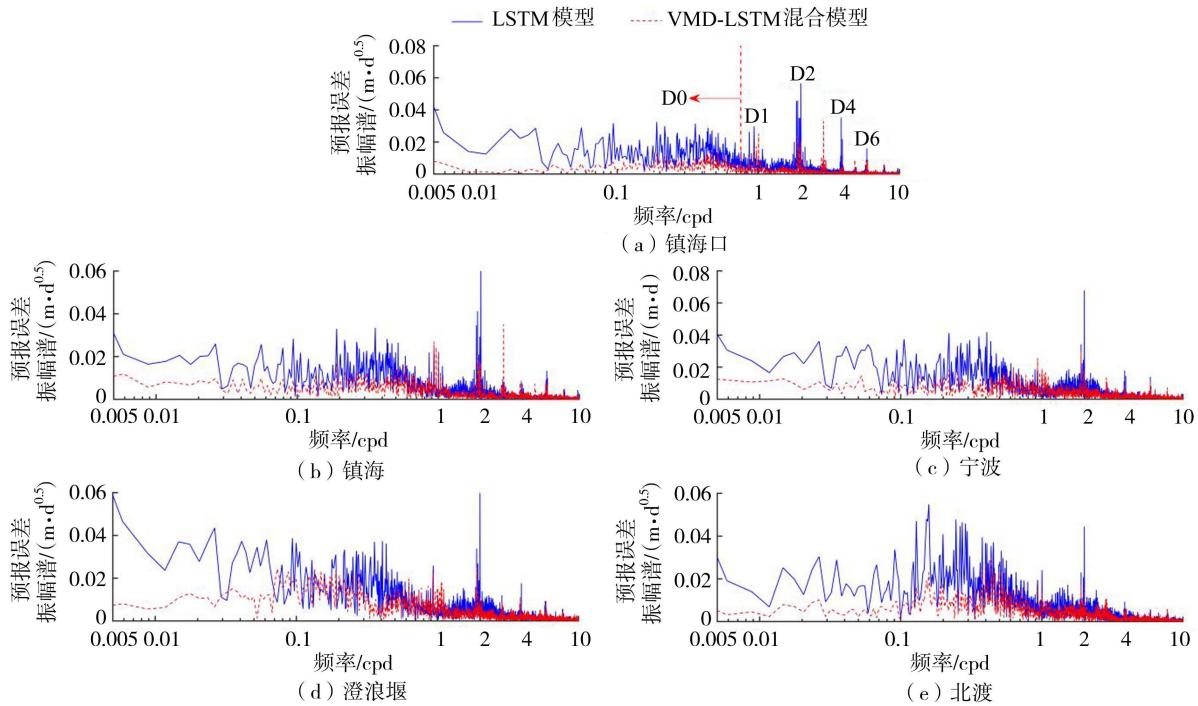


图 8 甬江口各水文站 24 h 逐时预报误差的振幅谱对比

Fig. 8 Comparison of the spectral distribution of 24 h prediction errors at each station in the Yongjiang River Estuary

由图 9 可知, VMD-LSTM 混合模型误差的走势与 LSTM 模型的走势较为接近, 但其值大部分情况下都比 LSTM 模型小。VMD-LSTM 混合模型也存在部分预报值与实测值偏差较大情况, 主要是 2~4 m 的水位且以 7—9 月居多, 属于台风高发月份。

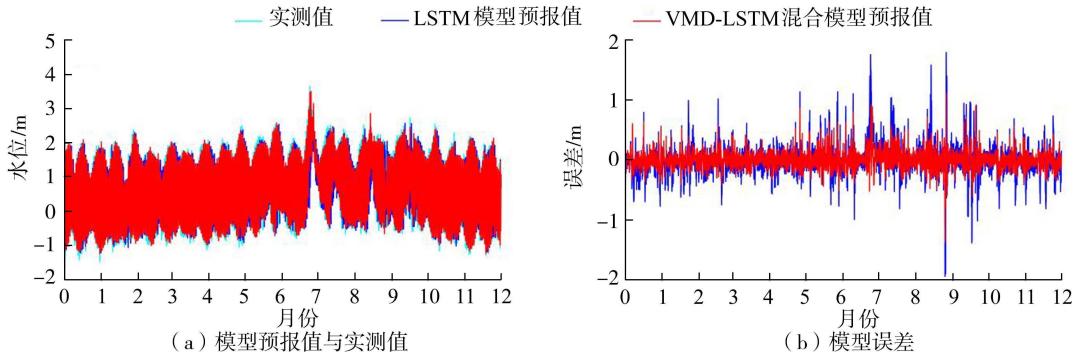


图 9 2021 年宁波站的 24 h 水位预报对比

Fig. 9 Comparison of the 24 h prediction water levels at Ningbo station in 2021

5 结 论

a. VMD 模型可对甬江河口余水位中 D0~D12 潮族波动进行完全分离, 不同时间尺度下的潮汐波动被严格划分为不同的模态, 所有潮族之间是完全分离的, $IMF_1 \sim IMF_{13}$ 分量都仅包含 D0~D12 潮族的能量, 不存在模态混叠问题。

b. 构建的 VMD-LSTM 混合模型的逐时预报精度显著高于 LSTM 模型。以 24 h 逐时预报为例, VMD-LSTM 混合模型的 RMSE 范围为 0.10~0.16 m, ± 0.30 m 合格率范围为 94.9%~99.0%, 均优于 LSTM 模型。做 48 h 逐时预报时, VMD-LSTM 混合模型也能保证 RMSE 不超过 0.22 m, ± 0.30 m 合格率达 90% 左右。

c. VMD-LSTM 混合模型 24 h 水位预报误差在各个频带的能量均低于 LSTM 模型。VMD-LSTM 混合模型在 D1、D4、D6 等主要潮族的预报结果也比 LSTM 模型更好, 但在 D0、D2 潮族频带的预报结果最好, 可将 D0、D2 的谱峰预报误差分别降低 0.02~0.05、0.02~0.04 $m \cdot d^{0.5}$ 。

参考文献:

- [1] 赵祥鸿,暴景阳,王一丁,等.余水位时变统计规律分析及水位预报方法改进[J].海洋测绘,2017,37(3):36-39. (ZHAO Xianghong, BAO Jingyang, WANG Yiding, et al. Time-varying statistical regularity of residual water level and improved method of water level predicting[J]. Hydrographic Surveying and Charting, 2017, 37(3):36-39. (in Chinese))
- [2] 杨正东,朱建荣,宋云平,等.长江口余水位时空变化及其成因[J].华东师范大学学报(自然科学版),2021(2):12-20. (YANG Zhengdong, ZHU Jianrong, SONG Yunping, et al. Spatial and temporal variations in the residual water level of the Changjiang Estuary and its cause[J]. Journal of East China Normal University (Natural Science), 2021(2):12-20. (in Chinese))
- [3] TALKER S A, JAY D A. Changing tides: the role of natural and anthropogenic factors[J]. Annual Review of Marine Science, 2020, 12:121-151.
- [4] DYKSTRA S L, DZWONKOWSKI B, TORRES R. The role of river discharge and geometric structure on diurnal tidal dynamics, Alabama, USA[J]. Journal of Geophysical Research: Oceans, 2022, 127(3):e2021JC018007.
- [5] MATTE P, JAY D A, ZARON E D. Adaptation of classical tidal harmonic analysis to nonstationary tides, with application to river tides[J]. Journal of Atmospheric and Oceanic Technology, 2013, 30(3):569-589.
- [6] 方国洪,郑文振,陈宗镛,等.潮汐和潮流的分析和预报[M].北京:海洋出版社,1986.
- [7] PAWLOWICZ R, BEARDSLEY B, LENTZ S. Classical tidal harmonic analysis including error estimates in MATLAB using T_TIDE[J]. Computers & Geosciences, 2002, 28(8):929-937.
- [8] GAN Min, CHEN Yongping, PAN Shunqi, et al. A modified nonstationary tidal harmonic analysis model for the Yangtze estuarine tides[J]. Journal of Atmospheric and Oceanic Technology, 2019, 36(4):513-525.
- [9] KUKULKA T, JAY D A. Impacts of Columbia River discharge on salmonid habitat: 1. a nonstationary fluvial tide model[J]. Journal of Geophysical Research: Oceans, 2003, 108(C9):3293.
- [10] PAN Haidong, LYU Xianqing, WANG Yingying, et al. Exploration of tidal-fluvial interaction in the Columbia River Estuary using S_TIDE[J]. Journal of Geophysical Research: Oceans, 2018, 123(9):6598-6619.
- [11] MATTE P, SECRETAN Y, MORIN J. Temporal and spatial variability of tidal-fluvial dynamics in the St. Lawrence fluvial estuary: an application of nonstationary tidal harmonic analysis[J]. Journal of Geophysical Research: Oceans, 2014, 119(9):5724-5744.
- [12] YU Xiayan, ZHANG Wei, HOITINK A J F. Impact of river discharge seasonality change on tidal duration asymmetry in the Yangtze River Estuary[J]. Scientific Reports, 2020, 10(1):6304.
- [13] CAI Huayang, YANG Qingshu, ZHANG Zihao, et al. Impact of river-tide dynamics on the temporal-spatial distribution of residual water level in the Pearl River channel networks[J]. Estuaries and Coasts, 2018, 41(7):1885-1903.
- [14] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [15] WILLIAMS R J, ZIPSER D. A learning algorithm for continually running fully recurrent neural networks[J]. Neural Computation, 1989, 1(2):270-280.
- [16] JOZEFOWICZ R, ZAREMBA W, SUTSKEVER I. An empirical exploration of recurrent network architectures[C]//Proceedings of the 32nd International Conference on Machine Learning. Lille: ACM, 2015:2342-2350.
- [17] 苑希民,黄玉啟,田福昌,等.基于LSTM-GM神经网络模型的风暴潮增水预报方法[J].水资源保护,2023,39(6):8-15. (YUAN Ximin, HUANG Yuqi, TIAN Fuchang, et al. Research on forecasting method of storm surge based on LSTM-GM neural network model[J]. Water Resources Protection, 2023, 39(6):8-15. (in Chinese))
- [18] 石卓,史东华,姚成,等.基于径流模数的LSTM模型在无资料嵌套流域的应用[J].河海大学学报(自然科学版),2024,52(3):51-57. (SHI Zhuo, SHI Donghua, YAO Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds[J]. Journal of Hohai University (Natural Sciences), 2024, 52(3):51-57. (in Chinese))
- [19] 徐嘉远,邹磊,夏军,等.TVGM-LSTM耦合模型及其径流模拟效果分析[J].水资源保护,2023,39(6):104-110. (XU Jiayuan, ZOU Lei, XIA Jun, et al. TVGM-LSTM coupling model and its runoff simulation effect analysis[J]. Water Resources Protection, 2023, 39(6):104-110. (in Chinese))
- [20] 田烨,谭伟丽,王国庆,等.LSTM变体模型在径流预测中的性能及其可解释性[J].水资源保护,2023,39(3):188-194. (TIAN Ye, TAN Weili, WANG Guoqing, et al. Performance of variant LSTM models in runoff prediction and their interpretability [J]. Water Resources Protection, 2023, 39(3):188-194. (in Chinese))
- [21] 郭燕,赖锡军.基于长短时记忆神经网络的鄱阳湖水位预测[J].湖泊科学,2020,32(3):865-876. (GUO Yan, LAI Xijun. Water level prediction of Lake Poyang based on long short-term memory neural network[J]. Journal of Lake Sciences, 2020, 32(3):865-876. (in Chinese))
- [22] 蒋晨凯,章四龙.基于贝叶斯优化与人工神经网络的秦淮河流域水位预报[J].水电能源科学,2022,40(9):48-51.

- (JIANG Chenkai, ZHANG Silong. Water level forecasting of Qinhuaihe River Basin based on Bayesian optimization and artificial neural network[J]. Water Resources and Power, 2022, 40(9) :48-51. (in Chinese))
- [23] 屠泽杰,邢喆,辛明真,等.基于集合经验模态分解与BP组合模型的短期余水位预测[J].海洋通报,2020,39(1):78-85.
(TU Zejie, XING Zhe, XIN Mingzhen, et al. Short-term residual water level prediction based on EEMD-BP neural network combination model[J]. Marine Science Bulletin, 2020, 39(1) :78-85. (in Chinese))
- [24] HUANG N E, SHEN Zheng, 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 A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971) :903-995.
- [25] PAN Haidong, GUO Zheng, WANG Yingying, et al. Application of the EMD method to river tides[J]. Journal of Atmospheric and Oceanic Technology, 2018, 35(4) :809-819.
- [26] 王亦斌,孙涛,梁雪春,等.基于EMD-LSTM模型的河流水量水位预测[J].水利水电科技进展,2020,40(6):40-47.
(WANG Yibin, SUN Tao, LIANG Xuechun, et al. Prediction of river water flow and water level based on EMD-LSTM model[J]. Advances in Science and Technology of Water Resources, 2020, 40(6) :40-47. (in Chinese))
- [27] WU Zhaohua, HUANG N E. Ensemble empirical mode decomposition:a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1) :1-41.
- [28] DRAGOMIRETSKIY K, ZOSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3) :531-544.
- [29] GAN Min, PAN Haidong, CHEN Yongping, et al. Application of the Variational Mode Decomposition (VMD) method to river tides[J]. Estuarine, Coastal and Shelf Science, 2021, 261 :107570.
- [30] GAN Min, CHEN Yongping, PAN Haidong, et al. Study on the spatiotemporal variation of the Yangtze estuarine tidal species[J]. Estuarine, Coastal and Shelf Science, 2024, 298 :108637.
- [31] 项新建,许宏辉,谢建立,等.基于VMD-TCN-GRU模型的水质预测研究[J].人民黄河,2024,46(3):92-97. (XIANG Xinjian, XU Honghui, XIE Jianli, et al. Waterquality prediction based on VMD-TCN-GRU model[J]. Yellow River, 2024, 46(3) :92-97. (in Chinese))
- [32] 张先起,赵玥,郑志文,等.基于VMD-AVOA-LSSVM模型的月降水量预测研究[J].水电能源科学,2022,40(12):1-5.
(ZHANG Xianqi, ZHAO Yue, ZHENG Zhiwen, et al. Study on prediction of monthly precipitation using VMD-AVOA-LSSVM model[J]. Water Resources and Power, 2022, 40(12) :1-5. (in Chinese))
- [33] 韩莹,王乐豪,魏平慧,等.水库水位的VMD-CNN-GRU混合预测模型[J].南京信息工程大学学报,2024,16(2):239-246.
(HAN Ying, WANG Lehao, WEI Pinghui, et al. VMD-CNN-GRU hybrid prediction model of reservoir water level[J]. Journal of Nanjing University of Information Science & Technology, 2024, 16(2) :239-246. (in Chinese))
- [34] 王瑞,陈泽坤,逯静.基于VMD和IBA-LSSVM的短期风电功率预测[J].河海大学学报(自然科学版),2021,49(6):575-582.
(WANG Rui, CHEN Zekun, LU Jing. Short term prediction of wind power based on VMD and IBA-LSSVM[J]. Journal of Hohai University (Natural Sciences), 2021, 49(6) :575-582. (in Chinese))
- [35] 张青,陶建峰,张长宽,等.浙江甬江潮波传播特征及影响因素分析[J].人民长江,2018,49(11):3-8. (ZHANG Qing, TAO Jianfeng, ZHANG Changkuan, et al. Analysis on tidal wave propagation characteristics and its influencing factors of Yongjiang River in Zhejiang Province[J]. Yangtze River, 2018, 49(11) :3-8. (in Chinese))
- [36] 郭明辰,张润润,闻余华.基于PSO-LSTM模型的平原河网汛期水位预测[J].水利水电科技进展,2024,44(6):64-70.
(GUO Mingchen, ZHANG Runrun, WEN Yuhua. Prediction of water level of plain river network during flood season based on PSO-LSTM model[J]. Advances in Science and Technology of Water Resources, 2024, 44(6) :64-70. (in Chinese))
- [37] 程文龙,胡成飞,樊立东,等.甬江潮汐不对称性数值模拟研究[J].人民长江,2022,53(6):168-173. (CHENG Wenlong, HU Chengfei, FAN Lidong, et al. Numerical simulation of tidal asymmetry in Yongjiang River[J]. Yangtze River, 2022, 53(6) :168-173. (in Chinese))