DOI: 10. 19650/j. cnki. cjsi. J2311886

基于能量熵 VMD 最优分解与 GRU 循环神经网络的 潮汐预测精度提升方法研究*

赵 杰,解则晓,刘世萱

(中国海洋大学工程学院 青岛 266404)

摘 要:为进一步提升潮汐预测精度,提高预测模型的多适应性,针对低频潮汐分潮智能化自适应提取困难、动态化处理分潮信 息能力弱、单一预测模型对潮汐整体预测的局限性等问题,提出了一种基于能量熵的自适应最优变分模态分解 VMD 与门控循 环单元神经网络 GRU 相结合的潮汐预测提升方法。首先,将潮汐数据归一化预处理,通过 VMD 对潮汐数据完成自适应变分模 态分解,并根据不同分解层模态分量的能量熵判定最优分解层数,最后将最优分量标准化后经 GRU 单独预测合成,通过反归一 化形成最终预测数据。经验证分析,在潮汐预测方面,GRU 模型比 LSTM、BiLSTM 模型性能更优,均方根误差分别提升了 53% 和 96.8%,而本文方法与单一 GRU 模型相比,均方根误差再次提升了 81.3%,预测精度提升效果更加明显,对于潮汐分析与预 测具有较高的推广应用价值。

关键词:潮汐预测;自适应最优变分模态分解;能量熵;门控循环单元 中图分类号: P714+.1 TH766 文献标识码: A 国家标准学科分类代码: 520.20

Tide prediction accuracy improvement method research based on VMD optimal decomposition of energy entropy and GRU recurrent neural network

Zhao Jie, Xie Zexiao, Liu Shixuan

(College of Engineering, Ocean University of China, Qingdao 266404, China)

Abstract: To improve the accuracy of tidal prediction further enhance the adaptability of the prediction model, and address a series of problems, including the difficulties of intelligent and adaptive extraction of low-frequency tidal components, weak ability to dynamically process tidal information, limitations of a single prediction model for overall tidal prediction, this paper proposes an improving tidal prediction model based on adaptive optimal variational modal decomposition of energy entropy and GRU recurrent neural networks. Firstly, the tidal data are normalized, and the VMD method is utilized for adaptive variational modal decomposition. Then, the optimal decomposition level is confirmed based on the energy entropy of the components. Finally, each component of the optimal decomposition is standardized and separately predicted and synthesized by GRU. The final prediction data are formed through reverse normalization. Through verification and analysis, compared with LSTM and BiLSTM models, the GRU model has better performance in terms of tidal prediction. The RMSE values are increased by 53% and 96.8%, respectively. However, compared with a single GRU model, the proposed prediction model has RMSE increase 81.3% again, and the accuracy improvement effect is more obvious. The method in this paper has high promotion and application value for tidal analysis and prediction.

Keywords: tidal prediction; adaptive variational model decomposition; energy entropy; GRU

0 引 言

潮汐是海洋水文动力观测重要参数之一,世界众多

收稿日期:2023-09-06 Received Date: 2023-09-06

沿海国家高度重视潮汐观测与预报技术,并部署了大量 长期验潮站用于潮汐数据长期观测和预报,在应对全球 气候变化、海洋防灾减灾、海上国防建设、海洋资源开发、 渔业捕捞及养殖、港口管理和建设等方面发挥了极其重

^{*}基金项目:国家重点研发计划(2022YFC3104200)项目资助

要的作用。随着海洋科技的进步以及全球海洋观测系统的建立和发展,国内外相关学者在现有潮汐实时观测数据基础上,深入研究了潮汐观测与预报模型算法。1)调和分析预报^[1-2],主要是利用潮汐数据时频域特性,对传统的调和分析方法予以改进。2)动力模型与数值模拟预报^[3-4],主要通过流场模式对潮波运动方程进行数值积分,实现潮汐潮流预报。截至目前,调和分析和数值模拟为主的传统潮汐预报方法已基本满足对潮汐长期稳定的预报需求。

近年来,为进一步提高预测精度和准确率,结合机器 学习、人工智能等一系列模型算法,新方法不断涌现,以 达到精确预报的目的,利用人工智能自学习、推理以及规 划能力进一步提高预报的学习效率和预测精度。Tu 等^[5]提出了一种采用调和分析、LSTM 网络和逆距离加权 插值算法进行整体预测的实时潮位预测方法,相关系数 为0.98,均方根误差达0.05 m,但只考虑风的影响; Raj 等[6] 通过人工神经网络预测了澳大利亚北部海岸线周围 的平均海平面,均方根误差可达0.04m,但方法缺少普适 性分析: Granata 等^[7]使用 M5P 回归树模型预测了威尼 斯城的潮位,相关系数可达0.99,相对绝对误差最低可 达5.98%,但未考虑气象因素的影响。Zhang 等^[8]使用 图卷积神经网络对区域内多个验潮站建立预报分析模 型,需依赖较大量历史数据作为支撑,且模型长短时预测 分类复杂度较高。Gao 等^[9]利用傅里叶基追踪谱实现潮 汐分析和预报,该方法未对潮汐分量成分迭代或遗漏情 况进行说明,且长短时预报普适性较差。李连博等[10]利 用对非线性外源自回归神经网络(nonlinear auto regressive with exogenous inputs, NARX)的改进方法完成 了潮位预测,与自适应粒子群 SAPSO-BP 网络以及传统 的 NARX 神经网络对比分析, 验证了该方法的精度和稳 定性,但该方法采用串并联模型进行训练和预报,并对天 文潮与非天文潮分类处理,增加了模型训练时间,算法实 现冗余度较高。秦思远等[11]提出了一种遗传算法和粒 子群算法结合(genetic particle optimization swarm, GPOS) 的 BP 神经网络,改善了传统模型和 BP 网络的预报精 度,但该方法依然是采用不同算法对天文潮与非天文潮 分类处理,导致模型算法冗余度较高。刘延^[12]提出了一 种粒子群算法(particle swarm optimization, PSO)优化支持 向量回归模型的港口潮汐预报算法,相较于与单一调和 分析模型以及 SVR 模型相比, 预测精度分别提升 70% 和 50%,但只针对不正规半日潮混合潮进行预测分析。周 建营等^[13]利用 Python 语言研制完成潮汐预报程序 HY_ analyser,经与 T_TIDE 软件相比一致性较好,但需大量可 靠有效数据作为支撑。

综上所述,目前潮汐预报方法存在普适性较差、算法 冗余度高、依赖长期的可靠有效数据和经验数据进行支

撑等问题,对于年度数据量较少、经验数据不足、潮汐 类型不明确的新建潮汐站实时预报算法研究较少。针 对这一现状,本文提出了基于能量熵的自适应最优变 分模态分解(variational model decomposition, VMD)与 门控循环单元神经网络(gate recurrent unit, GRU)相结 合的潮汐预测模型,利用短时分钟级潮汐数据,对未知 潮汐类型的新建潮汐站,实现预报效率和精度的提升, 解决目前潮汐预报算法对于大量年度数据的依赖、普 适性不高以及模型冗余度较高等问题。通过能量熵的 VMD 完成低频潮汐各模态最优提取,根据各模态分量 性能单独配置 GRU 训练参数,进一步提高了训练效率 和潮汐预报精度,同时该方法将各类因素引起的潮汐 变化纳入模型分析,并实现了最优分解,减少了冗余 度,提高了多适应性,无须再单独考虑天文潮、非天文 潮、气象等要素增加其他辅助类算法。经验证分析,本 文方法预测数据与实测数据的均方根误差为 0.19 cm, 平均绝对误差为 0.15 cm,同时与单一 GRU 相比,均方 根误差(root mean square error, RMSE)提升了 81.3%, 平均绝对误差(mean absolute error, MAE)提升了 83%, 平均百分比误差 (mean absolute percentage error, MAPE)提升了84.6%。

1 预测算法分析

受天文潮和非天文潮等各种因素的影响,潮汐数据 为各分潮能量谱的叠加,潮汐预测精度的提升主要依赖 分潮提取的可靠性和预测训练算法的有效性。基于能量 熵的 VMD 最优分解可实现分潮最优中心频率自适应提 取,解决分潮迭代或遗漏等问题。GRU 可根据最优分潮 特性单独训练,准确获取分潮长短时状态信息,解决预测 多适应性和效率等问题。

1.1 能量熵 VMD 最优分解

VMD 分解数量将影响潮汐预测的效果,当分解数量 较小时,潮汐重要谱信息会被滤除,影响后续预报准确 性;当分解数量较大时,相邻模态分量的中心频率会接近 重叠,导致模态重复或附加噪声。为避免模态混叠并保 证分潮信息无遗漏最优分解提取,采用能量熵的方式确 定 VMD 最优分解个数,用于后续预测。

1) VMD 自适应分解

VMD 采用非递归的求解方法,自适应地匹配每个模态 分量的最优中心频率和带宽范围^[14]。与传统经验模态分 解(empirical mode decomposition, EMD)不同,VMD 将模态 分量定义为调幅调频函数。VMD 将信号f(t)分解为少量 K个窄带本征模函数(intrinsic mode function, IMF),每个 模态用幅度和频率信号 $u_t(t)$ 表示,如式(1)所示。

$$\begin{cases} f(t) = \sum_{k=1}^{K} u_k(t) \\ u_k(t) = A_k(t) \cos(\varphi_k(t)) \end{cases}$$
(1)

式中: $A_k(t)$ 为模态幅值包络; $\varphi_k(t)$ 为模态相位。

将 $u_k(t)$ 经希尔伯特变换后,计算与其相关联的 实值函数,单边带调制绘制频谱。计算与 $u_k(t)$ 相关 联的实值函数的中心频率 $w_k(t)$,同时引入指数项 $e^{-j\omega_k t}$ 对其进行调节,使得各 IMF 频谱调制对应至基 频带。推导 L² 范数梯度的平方根,可得到 $u_k(t)$ 函数 的估计带宽,对应模型如式(2)所示,式中 $\delta(t)$ 为单 位脉冲函数^[15]。

$$\begin{cases} \min_{|u_k|, |w_k|} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-ju_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_k u_k(t) = f \end{cases}$$
(2)

求解变分通过引入拉格朗日因子 λ 和二次惩罚项 α ,将约束变分问题变成无约束变分问题。 u_k 、 w_k 与 λ 的 更新通过交替方向乘子法实现,同时寻找增广拉格朗日 表达式的"鞍点",以求得约束变分问题的最优解。增广 拉格朗日表达式如式(3)所示。

$$L(u_k, w_k, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left[\lambda(t) f(t) - \sum_k u_k(t) \right]$$
(3)

模态分量迭代寻找最优解,首先初始化 $u_k \ w_k = \lambda$, 当所有 $w \ge 0$,按照 VMD 算法公式更新 $u_k \ w_k$,并对拉格 朗日乘数 λ 双重提升,直到满足迭代约束条件后停止迭 代。迭代约束条件如式(4) 所示,其中 ε_r 和 ε_a 是指相对 公差和绝对公差。

$$\begin{cases} \sum_{k=1}^{K} \frac{\|u_{k}^{n+1}(t) - u_{k}^{n}(t)\|_{2}^{2}}{\|u_{k}^{n}(t)\|_{2}^{2}} < \varepsilon_{r} \\ \sum_{k=1}^{K} \|u_{k}^{n+1}(t) - u_{k}^{n}(t)\|_{2}^{2} < \varepsilon_{a} \end{cases}$$
(4)

IMF 分量与中心频率更新迭代公式如式(5)所示,其 中 $\hat{u}_{k}^{n+1}(w), \hat{u}_{i}(w), f(w), \hat{\lambda}(w)$ 分别为 $u_{k}^{n+1}(t), u_{i}(t), f(t), \lambda(t)$ 傅里叶变换。

$$\begin{cases} \hat{u}_{k}^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i=1, i \neq k}^{k} \hat{u}_{i}(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2\alpha(w - w_{k})^{2}} \\ w_{k}^{n+1} = \frac{\int_{0}^{\infty} |\hat{u}_{k}^{n+1}(w)|^{2} w dw}{\int_{0}^{\infty} |\hat{u}_{k}^{n+1}(w)|^{2} dw} \\ \hat{\lambda}^{n+1}(w) = \hat{\lambda}^{n}(w) + \gamma [\hat{f}(w) - \sum_{k=1}^{k} \hat{u}_{k}^{n+1}(w)] \end{cases}$$
(5)

IMF 能量熵计算

IMF 分量的能量熵 H。表达式如式(6) 所示^[16]。

$$H_{e} = -\sum_{j=1}^{k} p_{j} \lg p_{j}$$
(6)

其中, $p_j = E_j/E, E = \sum_{j=1}^{n} E_j, E_j = \sum_{i=1}^{n} |X_i|^2, E$ 为潮汐 时序数据的能量和, E_j 为固有模态分量 IMF, N 为潮汐时 序数据的信息长度; X_i 为潮汐时序数据的信息幅度。

1.2 GRU 门控循环单元神经网络

GRU 是比长短时记忆神经网络(long short-term memory, LSTM)结构更加简单的循环神经网络,与 LSTM 相比少了一个门,矩阵乘法变小,提高了数据模型训练效率,更易收敛和组建大的模型算法^[17]。GRU 结构由更新 门和重置门组成,其中更新门有助于捕捉时间序列的长 期依赖性,重置门有助于捕捉时间序列中的短期相关性。GRU 通过更新门和重置门控制数据更新,添加或删除状态信息而获得当前时间步 h.。

重置门和更新门的输入由当前时间步 x_i 和上一时间 步t-1的隐藏状态 h_{i-1} 组成。 h_i 通过更新门 z_i 、隐藏状态 h_{i-1} 和候选隐藏状态 \tilde{h}_i 获得。候选隐藏状态 \tilde{h}_i 由重置门 r_i 和t-1时间步隐含状态 h_{i-1} 相乘结果,与当前时间步 x_i 连结,通过 tanh 计算得出。计算公式如式(7)和(8)所 示。其中,W为输入权重矩阵,R为循环权重矩阵,b为 偏差矩阵, σ 为 sigmoid 函数; r, z, \tilde{h} 分别代表重置门、更 新门和候选状态。

$$\begin{cases} r_{t} = \sigma \left(x_{t} \boldsymbol{W}_{r} + \boldsymbol{h}_{t-1} \boldsymbol{R}_{r} + \boldsymbol{b}_{w_{r}} \right) \\ z_{t} = \sigma \left(x_{t} \boldsymbol{W}_{z} + \boldsymbol{h}_{t-1} \boldsymbol{R}_{z} + \boldsymbol{b}_{w_{z}} \right) \\ \tilde{h}_{t} = \tanh \left(x_{t} \boldsymbol{W}_{\tilde{h}} + \left(r_{t} \cdot \boldsymbol{h}_{t-1} \right) \boldsymbol{R}_{\tilde{h}} \right) \\ h_{t} = z_{t} \cdot \boldsymbol{h}_{t-1} + \left(1 - z_{t} \right) \cdot \tilde{h}_{t} \end{cases}$$

$$\boldsymbol{W} = \begin{bmatrix} \boldsymbol{W}_{r} \\ \boldsymbol{W}_{z} \\ \boldsymbol{W}_{\tilde{h}} \end{bmatrix}, \boldsymbol{R} = \begin{bmatrix} \boldsymbol{R}_{r} \\ \boldsymbol{R}_{z} \\ \boldsymbol{R}_{\tilde{h}} \end{bmatrix}, \boldsymbol{b} = \begin{bmatrix} \boldsymbol{b}_{w_{r}} \\ \boldsymbol{b}_{w_{z}} \\ \boldsymbol{b}_{w_{h}} \end{bmatrix}$$

$$(8)$$

1.3 潮汐预测模型

根据潮汐原理和时频特性,本文利用变分模态分解 VMD 对潮汐时序变化数据自适应匹配最优中心频率,并 通过能量熵判定潮汐有效分解个数,完成潮汐模态的最 优分解,将各模态分量完成标准化处理后,经门控循环单 元 GRU 神经网络单独预测预报,将分量预报值合成后作 为最终潮汐预报值。预测模型流程如图1所示。

2 潮汐样本数据

本文选取山东某海域浮子式验潮站观测的15天正 规半日潮汐数据(未经基准标定)进行潮汐预测模型的 实现与评估,数据采样频率为1 min。其中最高潮可达 821.2 cm,最低潮可达523.4 cm,15天内的最大潮差达 297.8 cm,时域信息如图2所示。



经对选取的 15 天潮汐数据频率谱分析,信息频率范 围集中在 0~5×10⁻⁵ Hz 之间,幅值最高点的频率分别为 2.27×10⁻⁵、1.17×10⁻⁵、3.44×10⁻⁶ 和 4.47×10⁻⁵ Hz 等,频 域分析如图 3 所示。



从频谱分布情况来看,观测信息包含了半日分潮、全日分潮 8 个主要分潮的频率范围和 1 个浅水 1/4 日分潮的频谱内容,但同时也包含了部分 3.44×10⁻⁶ Hz 等未在 11 个主要分潮中体现的较低频率分潮。从功率频谱覆盖情况来看,以 2.27×10⁻⁵、1.17×10⁻⁵、3.44×10⁻⁶ Hz 为中心点的分潮信息功率超过 10 dB, 6.87×10⁻⁷ ~ 3.436 99×10⁻⁶ Hz 频率范围内的分潮信息功率超过 5 dB,4.47×10⁻⁵ Hz 等浅水分潮信号功率小于 5 dB,信号功率频谱覆盖值如图 4 所示。



各个潮汐观测点分潮周期会因地域不同而有所差异, 用于潮汐预报的信息数据不能简单按照传统的11个分潮 来界定,应根据实测数据信息频谱分布情况统筹考虑,避 免造成无效信号冗余或有效信号损失,影响后续预报精度。

3 潮汐预测与验证

3.1 VMD 最优分解与预测

为降低潮汐数据有效信号损失或模态重复,提高预测精度,采用归一化方法对数据进行预处理,通过基于能量熵 VMD分解的方法,实现潮汐低频信号最优中心频率分解和 提取^[18]。最优分解个数通过 IMF 分量中心频率的能量熵情 况进行判定,各分量中心频率及能量熵如表1所示。

VMD 分解的 2~6 层中心频率主要集中在 4 个频段, 分别为 2. 27×10⁻⁵、1. 17×10⁻⁵、3. 44×10⁻⁶ 和 4. 47×10⁻⁵ Hz。 当分解层数为 5 时,分量 6. 74×10⁻⁵ Hz 中心频段能量熵 小于 0. 1%,且其余中心频段的能量熵和分解 4 层相比无 变化,因此,确定 VMD 的最优分解为 4 层,最优分解各分 量时域分布如图 5 所示。

VMD 最优分解 4 层后, 对各 IMF 分量进行提取, 从 各分量频谱频率分布来看, 最优分解 4 层各分量能量分 布合理, 频段分布清晰, 无模态重复情况, 较低能量模 表 1

VMD 模态分量中心频率表

Table 1 Center frequency table of VMD modal components										
分量	分解6层		分解5层		分解4层		分解3层		分解2层	
	中心频率/Hz	能量熵/%								
IMF1	7.91×10 ⁻⁵	0.01	6. 74×10 ⁻⁵	0.02	4. 47×10 ⁻⁵	0.33	2. 27×10 ⁻⁵	13.25	2. 27×10 ⁻⁵	12.76
IMF2	6.74×10 ⁻⁵	0.01	4.47×10 ⁻⁵	0.33	2. 27×10 ⁻⁵	13.28	1.17×10 ⁻⁵	25.95	1.17×10^{-5}	27.29
IMF3	4.47×10 ⁻⁵	0.33	2. 27×10 ⁻⁵	13.28	1. 17×10 ⁻⁵	25.93	3. 44×10^{-6}	7.46	—	—
IMF4	2. 27×10 ⁻⁵	13.28	1.17×10 ⁻⁵	25.93	3. 44×10 ⁻⁶	7.45	—	—	—	—
IMF5	1.17×10 ⁻⁵	25.93	3.44×10 ⁻⁶	7.45	—	—	—	—	—	—
IMF6	3.44×10 ⁻⁶	7.45	—	_	—	_	—	—	_	_





态均分布于残差。各模态分量实现了精准划分,更加有 利于提高后续潮汐数据预报精度。IMF 分量频谱分布图 如图 6 所示。

将 VMD 最优分解的 4 个 IMF 分量和 1 个残差分量,按照数据标准化处理并经 GRU 单独训练预测并 合成后,形成最终的预报数据。预测时间步数总计 7 273 步,单步时间为 1 min,约 5 天时间,预测数据如 图 7 所示。









从实际观测数据与预测数据对比来看,误差最大值 主要集中于高低潮部分,高潮误差最高达 0.46 cm,低潮 误差最高为-0.48 cm,数据预测总体的均方根误差为 0.19 cm,平均绝对误差为 0.15 cm,实时观测与预测误差 如图 8 所示。

3.2 预测验证与对比分析

本文按照统一的配置参数,采用 RMSE、MAE、MAPE 3 种评价方法对预测模型进行对比分析并验证 VMD 最 优分解层。其中预测模型通过与未经 VMD 分解的双向 长短期记忆网络(bidirectional long short-term memory,





BiLSTM)、LSTM、GRU 进行对比, VMD 最优分解预测按照3种评价方法在不同分解层的预测误差趋势进行验证^[19-20]。计算公式如式(9)~(11)所示,其中,*n* 为预测样本数量, *f_i* 为预测数据, *y_i* 为检验样本数据。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (f_i - y_i)^2}$$
(9)

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |f_i - y_i|$$
(10)

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} \left| \frac{f_i - y_i}{y_i} \right| \cdot 100\%$$
(11)

从潮汐预测值和实际观测数据拟合情况来看,本文 方法更接近实际观测值,预测数据拟合度较高,其余预测 拟合度较好的分别为 GRU、LSTM 和 BiLSTM,预测拟合 对比曲线如图9所示。



图 9 潮汐预测模型对比

Fig. 9 Comparison of tide prediction models

从预测模型评价指标数据来看,在神经网络训练配置参数相同的情况下,GRU、LSTM、BiLSTM 3 种模型中 GRU预测性能更优,RMSE 分别提升分别提升 53% 和 96.8%。而本文采用的 VMD 最优分解 4 层分解+GRU 预测方法与单一 GRU 相比, RMSE 提升了 81.3%, MAE 提升了 83%, MAPE 提升了 84.6%。预测模型精度提升 效果更加明显, 评价指标值如表 2 所示。

表 2 模型评价指标数据表 Table 2 Evaluation index data sheet of the predict model

预测模型	RMSE	MAE	MAPE
BiLSTM	32.12	25.61	3.97
LSTM	2.17	1.90	0. 28
GRU	1.02	0.88	0.13
VMD+GRU($k=2$)	0. 239	0.200	0.030
VMD+GRU($k=3$)	0.269	0.220	0.032
VMD+GRU($k=4$)	0. 187	0.150	0.022
VMD+GRU($k=5$)	0.460	0.390	0.058
VMD+GRU($k=6$)	0.400	0.310	0.046

从 VMD 分解层数预测评价指标曲线来看,最优分层 4 层的 RMSE、MAE、MAPE 3 项指标在 2~6 层分解的预 测误差最小,预测精度最高。经验证,采用基于能量熵的 自适应 VMD 分解方法实现潮汐预测是可靠有效的,评价 指标值如表 2 所示,分解层数用 k 表示。同时为突出 VMD 不同分解层评价指标的直观性,形成了指标对比 图,如图 10 所示。



图 10 VMD 分解层预测评价指标对比



3.3 预测模型多适应性验证

潮汐类型主要包括半日潮、全日潮和混合潮,其中混 合潮的主要特征为有些日子会出现两次高潮、两次低潮, 有些日子出现一次低潮、一次高潮的情况,因此采用混合 潮对本文方法的多适应性进行验证分析更具有代表性。 验证数据主要选取国内南海某河口验潮仪获取的 21 天 分钟级混合潮汐数据,如图 11 所示。根据混合潮汐谱分 析,潮汐主要受全日潮影响,同时含有较大半日潮,频谱 如图 12 所示。 赵





按照 VMD 最优分解方法,确定数据最优分解层数 为 5 层,将 IMF 分量和残差分量经 GRU 模型开环预测 合成最终的预报曲线如图 13~14 所示,其中均方根误 差 RMSE 为 0.72 cm,与未经 VMD 分解的单一 GRU 模 型相比预测精度提高了 32.7%。经验证,该预测模型 对于多种潮汐类型预测精度再提高具有较高的适 应性。







Fig. 14 Error of mixed tidal observation and prediction

4 结 论

本文主要研究基于能量熵的自适应最优变分模态分 解与 GRU 循环神经网络相结合的一种潮汐预测模型算 法,与单一 GRU 相比,该方法在正规半日潮和混合潮汐 预测的均方根误差分别提升了 81.3%和 32.7%,预测精 度提升效果较为明显,并验证了算法的多适应性,在潮汐 预报方面具有一定的推广应用价值,同时重点解决了以 下问题:

1)针对潮汐类型的不同以及由于地域、气象环境等 因素影响所导致的潮汐分潮呈现多样性和动态分类困难 等问题,采用 VMD 自适应最优变分模态分解方法,根据 外界信号变化自动调整滤波系数,实现低频潮汐分潮最 优中心频率和带宽范围的自适应匹配等。

2)针对 VMD 不同分解模态下原始信号重要信息容易被过滤或导致模态重复引入噪声等问题,通过不同分解层各模态的能量熵计算,判定最优分解个数 k,解决因信号分解不充分或冗余影响后续预测精度和效率等问题。

3)针对潮汐预测模型训练效率和预测精度提升等问题,通过对比分析 GRU、LSTM、BiLSTM 在潮汐预测的方面的性能,验证并确定了门控循环单元 GRU 神经网络在训练速度和精度方面的优势,通过 VMD 与 GRU 有效结合进一步提升了效率和预测精度。

参考文献

[1] 李阳东,李仁虎,常亮.基于高、低潮的潮汐调和常数 提取及潮汐预报[J].海洋湖沼通报,2020(2):55-63. LI Y D, LI R H, CHANG L. Tidal harmonic constants extraction and tidal prediction based on high and low tidal waters [J]. Transactions of Oceanology and Limnology, 2020(2):55-63.

- [2] NATHALIE G, ALEXA LGAEL A. Estimation of skew surge uncertainties when predicting tides in the past[J].
 Weather and Climate Extremes, 2023, 41:100597.
- [3] 马苑浩,汪求顺,周春艳,等.基于数值模拟的强潮海 湾潮汐预报模型精度分析:以三门湾为例[J].海洋技 术学报,2023,42(2):44-52.

MA Y H, WANG Q SH, ZHOU CH Y, et al. Accuracy analysis of tidal models of macro tidal bay based on numerical simulation: The example of sammen bay [J]. Journal of Ocean Technology, 2023, 42(2):44-52.

 [4] 刘经东,张文静,刘春笑,等.全球大洋潮汐模式在北 印度洋潮汐预报准确性的评估[J].海洋通报,2019, 38(2):159-166.

LIU J D,ZHANG W J,LIU CH X, et al. An assessment of tidal prediction by global ocean tide models in the North Indian Ocean [J]. Marine Science Bulletin, 2019, 38(2): 159-166.

- [5] TU Z, GAO X, XU J, et al. A novel method for regional short-term forecasting of water level [J]. Water, 2021, 13(6), DOI:10.3390/W13060820.
- [6] RAJ N, GHARINEIAT Z. Evaluation of multivariate adaptiveregression splines and artificial neural network for prediction of mean sea level trend around northern Australian coastlines [J]. Mathematics, 2021, DOI: 10. 3390/math9212696.
- [7] GRANATA F, DINUMNO F. Artificial intelligence models for prediction of the tide level in Venice [J]. Stoch Environ Res Risk Assess, 2021, 35:2537-2548.
- [8] ZHANG X L, WANG T F, WANG W, et al. A multi-site tide level prediction model based on graph convolutionalrecurrent networks [J]. Ocean Engineering, 2023, 269: 113579.
- [9] GAO F, WANG G C, et al. Tidal analysis and prediction based on the Fourier basis pursuit spectrum [J]. Ocean Engineering, 2023, 278:114414.
- [10] 李连博,武文昊,章文俊,等.改进非线性外源自回归
 网络的潮位实时预测[J].科学技术与工程,2022,
 22(22):9728-9735.

LI L B, WU W H, ZHANG W J, et al. Real-time tide level prediction model based on improved nonlinear auto regressive models neural network with exogenous inputs[J]. Science Technology and Engineering, 2022, 22(22):9728-9735.

- [11] 秦思远,李进军,龙冰心,等. 基于 GPOS-BP 神经网络 模型的潮汐预报[J].海洋信息,2020,35(2):1-5.
 QIN S Y, LI J J, LONG B X, et al. Tide forecast modelbased on GPOS-BP neural network [J]. Marine Information,2020,35(2):1-5.
- [12] 刘延. 基于改进 PSO-SVR 模型的港口潮汐预报算 法[J]. 测绘技术装备,2022,24(3):56-61.
 LIU Y. Port tide forecating algorithm based on improved PSO-SVR model [J]. Geomatics Technology and Equipment,2022,24(3):56-61.
- [13] 周建营,梁亚朋,陈国恒,等. 一种基于 Python 的潮汐 预报算法[J]. 热带地貌,2020,41(1):61-64.
 ZHOU J Y, LIANG Y P, CHEN G H, et al. A tide prediction algorithm based on python[J]. Tropical Geomorphology,2020,41(1):61-64.
- [14] ZENI Z, SINSING Y, LINGYUN J, et al. Hybrid VMD-CNN-GRU based model for short-term forecasting of wind power considering spatio-temporal features [J]. Engineering Applications of Artificial Intelligence, 2023, 121: 105982.
- [15] 计志勇,唐求,李雅鑫,等.基于 AVMD 与改进能量算子的非稳态谐波分析[J]. 仪器仪表学报,2022,43
 (7):209-217.
 JI ZH Y,TANG Q, LI Y X, et al. Power system harmonic

analysis under non-stationary situations based on AVMD and improved energy operator [J]. Chinese Journal of Scientific Instrument, 2022, 43(7):209-217.

- [16] 郭希海,徐峥,安丰强,等. 基于集合经验模态分解与 能量熵的水库群蓄水时期梯级水电调度模型[J].河 南科学,2023,41(6):801-808.
 GUO X H, XU ZH, AN F Q, et al. Cascade hydropower operation model of reservior group during impoundment period based on ensemble empirical mode decomposition and energy entropy[J]. Henan Science, 2023, 41(6): 801-808.
- [17] SONG X, LIANG J F. Research on red tideshort-time prediction using GRU network model based on multi-

feature Factors-A case in Xiamen sea area [J]. Marine Environmental Research, 2022, 182:13060820.

[18] 邢燕好,于昊,张佳,等.基于粒子群参数优化的
 0-VMD数据处理方法研究[J].仪器仪表学报,2023,
 44(4):304-313.

XING Y H, YU H, ZHANG J, et al. Research on the O-VMD thickness measurement data processing method based on particle swarm optimization [J]. Chinese Journal of Scientific Instrument, 2023, 44(4):304-313.

[19] 魏玮,吕游,齐欣宇,等.基于 CNN-LSTM-AM 动态集成 模型的电站风机状态预测方法[J]. 仪器仪表学报, 2023,44(4):19-27.

> WEI W, LYU Y, QI X Y, et al. State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model [J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.

[20] KRZYSZTOF Z, MACIEJ L. Advanced predictive control for GRU and LSTM networks [J]. Information Sciences, 2022,616:229-254.

作者简介



赵杰,中国海洋大学工程学院在读博 士、山东省科学院海洋仪器仪表研究所高级 工程师,主要研究方向为海洋潮汐波浪智能 观测技术,系统集成与信号处理。

E-mail: zhaojie83@126.com

Zhao Jie is a Ph. D. candidate in the College of Engineering at Ocean University of China. He is currently a senior engineer at the Institute of Ocean Instruments and Meters, Shandong Academy of Sciences. His main research interests include intelligent observation technology for ocean tides and waves, system integration and signal processing.



解则晓(通信作者),中国海洋大学工程 学院教授、博士生导师,主要研究方向为机 器视觉与智能机器人技术。

E-mail: xiezexiao@ouc.edu.cn

Xie Zexiao (Corresponding author) is a professor and a Ph. D. advisor in the College of

Engineering at Ocean University of China. His main research interests include machine vision and intelligent robot technology.