Doi:10.11840/j.issn.1001-6392.2022.04.005

# 基于非稳态调和分析和长短时记忆神经网络的 河口潮位短期预报混合模型

徐晓武 1.2, 陈永平 1.2, 甘敏 1.2, 刘畅 1.2, 周宏杰 3

(1. 河海大学 水文水资源与水利工程科学国家重点实验室, 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. 宁波市水文站, 浙江 宁波 315000)

摘 要:河口潮汐过程受上游径流、外海潮波等因素影响,动力机制复杂,潮位预报难度大。本文提出了一种基于非稳态调和分析(NS\_TIDE)和长短时记忆(ISTM)神经网络的混合模型,对河口潮位进行12~48h短期预报。该模型首先对河口实测潮汐数据进行非稳态调和分析,通过与实测资料对比得到分析误差的时序序列,并以此作为ISTM神经网络的输入数据,通过网络学习并预测未来12~48h潮位预报误差,据此对NS\_TIDE的预测结果进行实时校正。利用该模型对2020年长江口潮位过程进行了预报检验,结果表明混合模型12h、24h、36h和48h短期水位预报的均方根误差(*RMSE*)相比NS\_TIDE 模型至多分别降低了0.16m、0.15m、0.14m和0.12m;针对2020年南京站最高水位预测,NS\_TIDE 模型预报误差为0.64m,而混合模型预报误差仅为0.10m。

关键词:河口潮沙;长短时记忆神经网络;水位预报;长江口;非稳态调和分析模型
 中图分类号: P731.34
 文献标识码: A
 文章编号:1001-6932(2022)04-0401-10

# Hybrid model for short-term prediction of tide level in estuary based on LSTM and nonstationary harmonic analysis

XU Xiaowu<sup>1,2</sup>, CHEN Yongping<sup>1,2</sup>, GAN Min<sup>1,2</sup>, LIU Chang<sup>1,2</sup>, ZHOU Hongjie<sup>3</sup>

(1. State Key Laboratory of Hydrology–Water Resources & Hydraulic Engineering, Hohai University, Nanjing 210098, China;
 2. College of Harbour, Coastal and Offshore Engineering, Hohai University, Nanjing 210098, China;
 3. Ningbo Hydrology Station, Ningbo 315000, China)

**Abstract:** The tidal process in estuary is affected by comprehensive factors such as river discharge and astronomical tidal, as a result, the estuarine tide level is difficult to predict. In this paper, a hybrid model based on the nonstationary harmonic analysis model (NS\_TIDE) and long short-term memory (LSTM) neural network is proposed to predict the estuarine tidal level for 12–48 hours. The hybrid model carries out nonstationary harmonic analysis of the measured tidal level firstly, and obtains the time series of the analysis error by comparing with the measured data. The analysis errors are considered as the input data of the LSTM neural network to predict the tidal prediction error in the next 12 h to 48 h, so as to correct the prediction of NS\_TIDE in real time. The hybrid model is used to predict the tide level in the Changjiang Estuary in 2020. The results show that the root mean square error (*RMSE*) of the short-term water level prediction of the hybrid model at 12 h, 24 h, 36 h, and 48 h is reduced by up to 0.16 m, 0.15 m, 0.14 m, and 0.12 m respectively compared with the NS\_TIDE model. For the prediction of the highest water level of Nanjing Station in 2020, the prediction error of the hybrid model is 0.10 m, while that of NS\_TIDE is 0.64 m.

Keywords: estuary tides; LSTM; water-Level prediction; Changjiang Estuary; NS\_TIDE;

收稿日期: 2022-01-03; 修订日期: 2022-03-21

基金项目:国家自然科学基金 (51979076);中央高校基本科研业务费项目 (B200204017);宁波市水利科技项目 (NSKA202205) 作者简介:徐晓武 (1998—),硕士研究生,主要从事海岸风暴灾害防灾减灾研究。电子邮箱: 1025223833@qq.com 通讯作者:陈永平,博士,教授。电子邮箱: ypchen@hhu.edu.cn

河口地区是人类活动最为频繁,也是生态环境 保护重点关注的区域。河口潮位的准确预报对于保 护河口地区人民生命财产安全,促进经济可持续发 展有着重要作用,同时也为科学开展生态环境保护 与修复提供了必要的数据支撑。河口地区的潮汐过 程既受到外海潮波的控制,也受到上游径流的影 响,径潮相互作用的存在给河口潮位的准确预报带 来了较大困难。

外海及近岸区域潮汐主要是由引潮力引起的水体波动,具有周期性,其潮位可通过 T\_TIDE 模型<sup>III</sup>等经典调和分析(Classical Harmonic Analysis, CHA)方法进行高精度预报;而当潮波向河口上游 传播时,受径流的非线性作用及浅水效应影响,分 潮特征(振幅与迟角)具有时变性,与 CHA 方法 的分潮特征稳定为常数的假定不符,导致 CHA 方 法对河口潮汐模拟结果误差较大<sup>I2-4</sup>。

针对河口潮汐的特点,Kukulka 等<sup>15-6</sup>以哥伦比 亚河口为例详细阐述了河流流量以及外海潮汐对分 潮特征的非线性作用。Matte 等<sup>17</sup>基于前人研究提出 了非稳态调和分析(NS\_TIDE)模型,并利用该模 型对哥伦比亚河口潮汐进行了研究。Zhang 等<sup>18</sup>和 Cao 等<sup>19</sup>将该模型应用于我国珠江口区域,取得了 较好的分析结果。Gan 等<sup>12</sup>在长江口区域对该模型 的适用性做了进一步研究,发现 NS\_TIDE 对低频 (0~0.03 cph)分潮的模拟误差相对较大,从而影响 了该模型在长江口的整体表现,预报精度相对偏低。

事实上,回归预测是数据驱动模型的经典应用 之一,因此将数据驱动模型用于预测潮位极具潜力。 相对于基于物理过程的分析方法,数据驱动模型不 需要特定的函数关系式,它具有很好的学习能力。 数据驱动模型通过对历史数据进行训练,能够模拟 数据间的非线性甚至未知关系,实现预测功能。

目前,数据驱动模型在潮位预测中的应用主要 有两种模式,一种为直接预报模式,即利用数据驱 动模型,通过大量数据学习输入特征与潮位的非线 性关系,再利用训练好的模型对潮位进行预报<sup>[9-16]</sup>。 第二种为混合预报模式,结合水动力模型或调和分 析模型,利用数据驱动模型对上述模型结果进行误 差修正而获得短期高精度的潮位预报<sup>[17-19]</sup>。就目前 研究来看,数据驱动模型在潮位预报上的研究主要 集中于沿海潮汐过程,而对河口潮位预报的研究较 少。针对第一种模式, Gan 等<sup>[20]</sup>基于 LightGBM 决 策树,以分潮等特征为输入层建立了哥伦比亚河口 潮位预报模型,但该模型相比于 NS\_TIDE 模型精 度提升有限。Chen 等四采用第二种预报方式,研 究结果证明了 NS\_TIDE 预测误差具有自相关性, 并利用自回归模型(Auto-Regressive, AR)修正 NS\_TIDE 预报水位的方法进行了长江口水位高精 度短期预报,但该模型在每一时间步预测中都需重 新训练模型且至少需要前 1440 步时间序列用于 AR 模型训练,当存在大量的缺测数据时,模型精 度将会显著降低。

随着人工智能的快速发展,深度学习因其强大的非线性映射能力成为数据驱动的重要方法之一。 长短时记忆(Long Short Term Memory, LSTM)模型是由 Hochreiter等<sup>[21]</sup>建立的深度学习模型,是一种特殊的递归神经网络(Recurrent Neural Network, RNN)<sup>[23]</sup>,它能够较好地捕捉数据间的长期依赖关系。LSTM模型通过建立历史数据与未来数据的非 线性映射关系进行数据预测,它在单元内部设置的 门控结构克服了 RNN梯度消失、长期记忆能力弱 等缺点<sup>[22-24]</sup>,是一种有效的序列数据预测模型。目 前,LSTM模型被广泛应用于金融<sup>[25-27]</sup>、能源<sup>[28-29]</sup>和 交通<sup>[30-32]</sup>等领域。

Chen 等<sup>[21]</sup>的研究表明,NS\_TIDE 模型的河口 水位预测误差存在较强的自相关性,可知该误差时 间序列具有一定的可学习信息。故本文提出了一种 基于 NS\_TIDE 和 LSTM 的短期河口潮位混合预报 模型,简称 NS\_TIDE&LSTM 混合模型,它利用 LSTM 模型对 NS\_TIDE 的潮位预测值进行误差矫 正,以提高河口潮位短期预报精度。

# 1 研究区域及资料

#### 1.1 研究区域概况

长江口是长江入海的主要通道(图1),其 所在的地区是我国经济最为发达的区域之一<sup>[33]</sup>。 长江口潮型以不规则半日潮为主,平均潮差约为 2.67 m<sup>[34-35]</sup>。长江口洪季为每年5月至10月,枯季 为每年11月至次年4月。其径流量具有显著的季 节性变化,汛期入海流量约占全年的71%<sup>[36]</sup>。受潮 汐和径流等海陆因素交互作用的影响,长江口动力 机制复杂,其潮位的准确预报一直是研究的热点与 难题<sup>[37-39]</sup>。



#### 1.2 研究资料

4 期

以下游吴淞站为坐标原点,本文用到的水文站 点分布及站点间距离如图 1 所示。吴淞站、江阴 站、三江营站、镇江站和南京站包含 2013-2020 年的逐时实测水位,而大通站包含同时间段的实测 径流。图 2 (a) 为大通站 2013-2020 年流量过程 线,其流量具有一定的年际波动,且 2020 年汛期 时流量达到近 7 年最高。按照 NS\_TIDE 模型的要 求,需确定上游的流量参考站及下游的潮差参考 站。考虑到大通站基本不受潮汐影响,故选取大通 站作为流量参考站;由于潮差参考站需选取受径流 影响最小的站点,故图2(b)统计了各站点水位 与流量互相关系数值。越向下游,水位与流量相关 性越小,吴淞站与流量相关性最小,故选取吴淞站 作为潮差参考站。根据长江口径流与潮汐动力特 点,江阴站一般被视为分界点,江阴以下为潮动力 占优,江阴以上为径流动力占优。因此,本文主要 研究的站点均位于受径流影响显著的感潮河段。



图 2 2013-2020 年大通站流量过程线及站点水位流量互相关系数统计

http://hytb.ijournals.cn

# 2 模型介绍

#### 2.1 NS\_TIDE 模型

为提高河口地区潮位预报精度,Matte等<sup>m</sup>提出 了考虑径流与外海潮差非线性影响的非稳态调和分 析模型 NS\_TIDE,其潮位方程 *f*(*t*)如下:

$$f(t) = A_0 + \sum_{k=1}^n \left( B_k \cos(\sigma_k t) + D_k \sin(\sigma_k t) \right)$$
(1)

式中: f(t) 为河口潮位; n 为分潮总数; k 为分潮 索引;  $\sigma_k$  为第 k 个分潮角频率; t 为时间。等号右 边第一项  $A_0$  为 NS\_TIDE 中的亚潮水位模块(stage model), 它表征了低频分潮(频率为 0~0.03 cph) 的平均水位波动;等号右边第二项为模型的径潮模 块(tidal-fluvial model), 它表征了分潮(频率为 0.03~0.05 cph)的水位波动。式中  $A_0$ 、 $B_k$ 和  $D_k$ 均 为与径流、潮差相关的时变量,表达式如下:

$$A_{0} = c_{0} + c_{1}Q_{\rm R}^{P_{\rm s}}(t - t_{\rm Q}) + c_{2}\frac{R^{q_{\rm s}}(t - t_{\rm R})}{Q_{\rm R}^{r_{\rm s}}(t - t_{\rm Q})}$$
(2)

$$B_{k} = d_{0,k}^{c} + d_{1,k}^{c} Q_{R}^{p_{f}}(t - t_{Q}) + d_{2,k}^{c} \frac{R^{q_{f}}(t - t_{R})}{Q_{R}^{r_{f}}(t - t_{Q})}$$
(3)

$$D_{k} = d_{0,k}^{s} + d_{1,k}^{s} Q_{\rm R}^{p_{\rm f}}(t - t_{\rm Q}) + d_{2,k}^{s} \frac{R^{q_{\rm f}}(t - t_{\rm R})}{Q_{\rm R}^{r_{\rm f}}(t - t_{\rm Q})}$$
(4)

式中:角标 s、f分别代表了亚潮水位模块和径潮 模块; $Q_{R}$ 和 R分别为流量参考站和潮差参考站的 低通流量和潮差; $t_{Q}$ 、 $t_{R}$ 分别为径流与外海潮汐传 播至该站点的滞后时间; $c_{i}$ 、 $d_{i,k}$  (i = 0, 1, 2)分 别为亚潮水位模块和径潮模块的未知位置参数;  $p_{s}$ 、 $q_{s}$ 、 $r_{s}$ 、 $p_{f}$ 、 $q_{f}$ 、 $r_{f}$ 为未知指数。

#### 2.2 LSTM 模型

长短时记忆(LSTM)神经网络通过建立历史 与未来数据间的映射关系进行预测,是一种强大的 序列数据预测模型,其基本单元结构如图 3 所示。 单元结构包含遗忘门、输入门及输出门,其中遗忘 门通过输入 x<sub>t</sub> 及上一单元输出 h<sub>t-1</sub> 决定从上一单元 状态中丢弃哪些信息,输入门对 x<sub>t</sub> 进行 sigmoid 及 tanh 函数变换决定对单元状态添加哪些新的信息, 最后输出门由更新后的单元状态 C<sub>t</sub> 及输出门状态 O<sub>t</sub> 决定单元输出 h<sub>t</sub>。其计算公式如式(5)-(10) 所示。

$$f_{t} = \text{sigmoid}(W_{f} \cdot [h_{t}, x_{t}] + b_{f})$$
(5)

$$i_{i} = \text{sigmoid}(W_{i} \cdot [h_{i-1}, x_{i}] + b_{i})$$
(6)

$$C_{t} = \tanh(W_{c} \cdot [h_{t-1}, x_{t}] + b_{c})$$
(7)

$$O_{t} = \text{sigmoid}(W_{o} \cdot [h_{t}, x_{t}] + b_{o})$$
(8)

$$C_{t} = f_{t} \times C_{t-1} + i_{t} \times C_{t}$$

$$\tag{9}$$

$$h_t = O_t \times \tanh(C_t) \tag{10}$$

式中:  $f_i$ 、 $i_i$ 、 $C_i$ 、 $O_i$ 分别代表了遗忘门、输入门及 输出门的状态向量;  $W_f$ 、 $W_i$ 、 $W_e$ 、 $W_o$ 分别对应了 各门控的权重矩阵;  $b_i$ 、 $b_i$ 、 $b_e$ 、 $b_o$ 分别对应了各门 控的偏置向量;  $C_i$ 、 $C_{i-1}$ 分别为当前单元及上一单 元的状态向量;  $h_i$ 、 $h_{i-1}$ 分别为当前单元输出及上 一单元的输出向量。·代表矩阵点乘; ×代表向量 按位相乘。



# 3 模型构建

#### 3.1 数据准备

#### 3.1.1 NS\_TIDE 模型性能验证

为检验 NS\_TIDE 在长江口的适用性,本文利 用 NS\_TIDE 模型对江阴站、三江营站、镇江站和 南京站 2013—2020 年逐时水位进行模拟分析。以 2013 年逐日每小时的潮位数据(8 760 h)对 NS\_TIDE 进行模型系数回归,同时应用 T\_TIDE 模 型对相同站点进行传统的调和分析,以对比检验 NS\_TIDE 模型在长江口的预测性能。图 4 对比了 两个模型在各站点上的均方误差,可见 NS\_TIDE 模型在长江口处性能远优于经典调和分析模型,其 均方误差在 0.19~0.25 m 之间。如图所示,从江阴 站至南京站,T\_TIDE 与 NS\_TIDE 性能差逐渐增 大,这是由于越向上游,流量对分潮特征的影响越 大,T\_TIDE 模型效果越差,而 NS\_TIDE 由于考虑

了径流与外海潮波的非线性作用,在各站点的预测 性能都相对较优。同时, Chen 等四通过误差谱分 析发现 NS TIDE 误差存在低频周期性,即存在一 定的自相关性,而 LSTM 模型特别适合于预测此类 数据, 故本文采用 LSTM 模型对 NS TIDE 的误差 进行预测,以进一步提高河口水位短期预报精度。



3.1.2 数据集划分

深度学习数据集主要分为训练集、验证集及测 试集三类。模型在训练集上训练模型参数,在验证 集上评估训练过程中模型的性能以及收敛情况,最 后在测试集上验证训练完成后的模型性能。本文选 用 NS TIDE 模型在 2014-2020 年的水位预报误差 序列数据(共61368个)用于模型试验,选取 2014-2019 年误差序列数据(共 52 584 个)用于 LSTM 模型训练,其中 70%数据作为训练集,剩余 30%数据用作验证集,选用 2020 年预测误差数据 (8784个)作为测试集,测试模型性能。

# 3.2 NS TIDE&LSTM 模型构建

本文提出的 NS\_TIDE&LSTM 混合模型以 NS TIDE 模拟误差序列为输入,通过 LSTM 模型预 测 NS\_TIDE 预报误差,进而矫正 NS\_TIDE 预报结 果,提高河口水位短期预报精度。LSTM 模型的框



图 5 模型框架图

4 期

架如图 5 所示,模型由输入层、隐藏层及输出层三 部分组成。其中输入层部分负责对 NS\_TIDE 模拟 误差进行数据集划分,并分割数据以使其满足网络 输入要求;隐藏层部分由多层 LSTM 网络及全连接 神经网络组成;输出层负责提供模型预测结果,模 型预测采用多步预测模式。

LSTM 模型参数需要通过敏感性分析进行最优 查询,如图 5 所示,需要调节的主要模型参数为 LSTM 层数、全连接层神经元数目、LSTM 记忆神 经元数目、输入数据长度及批尺寸。最优参数的确 定以模型在验证集上的预测性能(以均方根误差 RMSE 表征)作为评估指标,首先根据经验初定参 数范围,然后进行重复试验对比模型在各参数下的 评估指标并选取最小值对应的参数作为最优参数。

LSTM 层数及每层记忆神经元数决定了模型的 复杂度,层数过少会导致模型欠拟合,过多则会导 致模型的过拟合。为确定最优 LSTM 层数,本文设 置 4 组层数进行试验,表1统计了不同层数下模型 在验证集的预测均方根误差。由表1可知,适当增 加 LSTM 层数有助于模型精度提升,但当层数增加 到 3 时,验证集误差提升,表明此时模型存在过拟 合。故为了最佳的模型性能,将模型隐藏层中 LSTM 层数设定为2 层。

LSTM 层数	验证集 RMSE /m
1	0.087
2	0.084
3	0.087
4	0.090

表1 不同 LSTM 层数的模型均方根误差

针对 LSTM 记忆神经元数目以及全连接层神经 元数目,设计了 20 组神经元数目组合进行试验, 试验结果如图 6 (a)所示,可以发现当各层 LSTM 中记忆神经元数为 128 及全连接层神经元数为 100 时,模型精度最高。批尺寸是模型训练更新权重的 重要参数,它决定了模型的训练速度和性能,为确 定最优批尺寸,进行了 5 组不同批尺寸的模型测 试,结果如图 6 (b)所示,可知批尺寸为 128 时, 验证集误差最小。同时,合理确定输入数据的长度 有助于模型学习数据历史信息关系,同时可使模型 训练高效且快速。图 6 (c)为不同输入数据长度 的模型性能,可知输入数据长度为 24 h 时验证集 误差最小,即利用前 24 h 数据预测时模型精度最 优,这可能与潮位的周期性有关。至此,模型参数 寻优完成。对于12h、36h和48h的预测模型参 数寻优方法同上,参数寻优结果如表2所示。



# 4 模型应用分析

为验证 LSTM 模型对 NS\_TIDE 误差的预测性能,本文以南京站 2020 年 1 月及 2020 年 9 月潮汐预报为例,利用训练好的 LSTM 模型进行未来误差

表 2 模型最优参数				
参数	12 h 预测模型	24 h 预测模型	36 h 预测模型	48 h 预测模型
LSTM 层数	2	2	2	2
神经元数组合	[256, 256, 200]	[128, 128, 100]	[64, 64, 100]	[256, 256, 100]
批尺寸	32	128	128	64
输入数据长度	12	24	36	48

的预测。以24h预测为例,图7对比了LSTM模 型的预测值与 NS TIDE 实际预测误差。可知 LSTM 对未来误差的预测结果虽然在少数的极值点处与 NS TIDE 实际预测误差有一定的差异,但在整体 上能够较好地预估 NS TIDE 预测误差。同时,对 比图 7 (a) 和图 7 (b) 可以发现, 对于周期性较 强的序列,LSTM 的预测性能更优。



图 7 南京站 LSTM 模型误差预报与 NS\_TIDE 预测误差对比图

上述测试证明了利用 LSTM 模型预报 NS TIDE 模拟误差的可行性。为进一步验证 NS\_TIDE&LSTM模型预测性能,对 2020 年南京站 全年逐时水位进行预报,图8为24h预见期的 NS TIDE&LSTM 模型与 NS TIDE 模型预测水位曲 线对比图。由图可知,当水位低于6m时,两模型 预报值均与实测值拟合较好;当水位高于6m时,

NS\_TIDE&LSTM 模型预测精度要明显优于



图 9 (a) 为 24 h 预见期的 NS\_TIDE&LSTM 模 型与 NS\_TIDE 模型在南京站洪季期间(2020 年6-9月)的预测水位曲线对比图。NS TIDE&LSTM 预 测水位与实测水位拟合较好, LSTM 模型较好地矫 正了 NS\_TIDE 模型的预测值。图 9(b) 为 2020 年最高水位期间的预测水位曲线对比图,两模型预 报及实测最高水位值分别为11.02 m、10.48 m 和 10.38 m, NS\_TIDE&LSTM 模型在最高水位的预测 误差为 0.10 m,显著优于NS\_TIDE 模型的表现。

图 10 统计了 12 h、24 h、36 h、48 h 预见期的 NS TIDE&LSTM 预报模型在各站点 2020 年逐时潮 位、高潮位及低潮位预报的均方根误差(RMSE), 如图 10(a) 所示,不同预见期的NS TIDE&LSTM 预测模型在各站点的逐时水位预测精度均优于 NS\_TIDE, 以 24 h 预报为例, NS\_TIDE&LSTM 模 型将 NS TIDE 逐时水位预测的均方根误差从 0.19~ 0.25 m 降至 0.09~0.15 m, 对于48 h 预报将模型均 方根误差降低至少 0.04 m。高低潮位的精确预报 对洪枯季灾害防护以及港航工程建设极其重要, 图 10(b)和图 10(c)分别统计了各模型对高低潮位 的预测误差。相比于图 10(a) 的逐时水位预测误 差,NS\_TIDE 模型在高潮位的预测误差有所增加,





图 9 NS\_TIDE 与 NS\_TIDE&LSTM 模型南京站洪季预测水位过程线对比

图 10 NS\_TIDE 和 NS\_TIDE&LSTM 模型 12~48 h 预报精度统计

http://hytb.ijournals.cn

而对低潮位的预测误差有所降低。由于混合模型是基于NS\_TIDE 预测结果进行校正的,故其在高低潮位预测性能的变化与 NS\_TIDE 预测性能变化相同。但整体而言,不论是针对高潮位还是低潮位的预报,LSTM 模型均能较好地校正NS\_TIDE 的预测结果,且预报均方误差均在 0.17 m 以内。

为分析模型高精度预报的时长阈值,图 11 统 计了进行参数优化后的 12~240 h (间隔为 12 h) 预见期的 NS\_TIDE&LSTM 预报模型在各站点 2020 年逐时水位预报均方根误差。如图 11 所示,随着 预报时长的增加,受到不确定性因素的影响增大, 混合模型的预测精度降低。以降低NS\_TIDE 预测 均方根误差 0.04 m 为高精度阈值,由图可知针对 江阴站、三江营站、镇江站以及南京站,模型进行 高精度预报时长的阈值分别为 48 h、204 h、228 h 及 84 h。



图 11 12~240 h 预见期混合模型在各站点的逐时水位预报均方根 误差

# 5 结 论

本文基于 NS\_TIDE 模型和 LSTM 模型,构建 了河口短期水位预报混合模型,并将其应用于长江 口沿程各站的潮位 12~48 h 的短期预测,得到结论 如下。

(1) LSTM 网络参数敏感性研究结果表明,适 当增加 LSTM 层数有助于提高模型精度,但LSTM 层数过多则会导致模型过拟合而降低模型性能;模 型最佳输入数据长度与模型预测序列长度相同,即 使数据序列中存在少量的缺测数据,预报仍能保持 较高的精度。

(2) NS\_TIDE&LSTM 混合模型的预报精度明

显优于 NS\_TIDE 模型,尤其在 2020 年南京站年最高水位预测上,模型预测误差为 0.10 m,远低于 NS\_TIDE 模型的 0.64 m。通过与实测资料的对比,混合模型在长江口 2020 年全年 24 h 逐时水位、高潮位及低潮位预报均方根误差分别为 0.09~0.15 m 及 0.07~0.15 m,而 NS\_TIDE 则分别为 0.19~0.25 m 及 0.20~0.25 m 及 0.18~0.24 m。

(3) 对混合模型的高精度预报时长研究结果表明,以降低 NS\_TIDE 预报均方根误差 0.04 m 为阈值,江阴、三江营、镇江及南京站的高精度预报时长阈值分别为 48 h、204 h、228 h 及 84 h。

需要指出的是,本文建立的 NS\_TIDE&LSTM 模型能够较为精确地进行长江河口潮位短期预报。 但受 LSTM 模型自身学习能力的限制,模型对长期 时序数据预测精度不高,如何构建高精度的长期河 口水位预报模型仍需进一步研究。同时,本文仅将 模型应用于长江河口沿程站,考虑到不同河口的动 力特征不一致,其在其他河口的适用性仍有待进一 步研究。

### 参考文献

- 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.
- [2] GAN M, CHEN Y, PAN S, 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.
- [3] CAO Y, ZHANG W, ZHU Y, et al. Impact of trends in river discharge and ocean tides on water level dynamics in the Pearl River Delta[J]. Coastal Engineering, 2020, 157: 103634.
- [4] YU X, ZHANG W, 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): 1–17.
- [5] 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.
- [6] KUKULKA T, JAY D A. Impacts of Columbia River discharge on salmonid habitat: 2. Changes in shallow-water habitat[J]. Journal of Geophysical Research: Oceans, 2003, 108(C9): 3294.
- [7] 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.
- [8] ZHANG W, CAO Y, ZHU Y, et al. Unravelling the causes of tidal asymmetry in deltas[J]. Journal of Hydrology, 2018, 564: 588–604.
- [9] LEE T L, JENG D S. Application of artificial neural networks in

tide-forecasting[J]. Ocean Engineering, 2002, 29(9): 1003-1022.

- [10] CHEN B F, WANG H D, CHU C C. Wavelet and artificial neural network analyses of tide forecasting and supplement of tides around Taiwan and South China Sea [J]. Ocean Engineering, 2007, 34(16): 2161–2175.
- [11] SALIM A M, DWARAKISH G S, LIJU K V, et al. Weekly prediction of tides using neural networks [J]. Procedia Engineering, 2015, 116: 678–682.
- [12] MEENA B L, AGRAWAL J D. Tidal level forecasting using ANN[J]. Procedia Engineering, 2015, 116: 607–614.
- [13] YANG C H, WU C H, HSIEH C M. Long short-term memory recurrent neural network for tidal level forecasting [J]. IEEE Access, 2020, 8: 159389–159401.
- [14] GRANATA F, DI NUNNO F. Artificial Intelligence models for prediction of the tide level in Venice[J]. Stochastic Environmental Research and Risk Assessment, 2021, 35(12): 2537–2548.
- [15] 薛明,李醒飞,成方林.基于多种神经网络的风暴潮增水预测方 法的比较分析[J].海洋通报,2019,38(3):290-295.
- [16] 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.
- [17] ZHANG Z, YIN J, WANG N, et al. A precise tidal prediction mechanism based on the combination of harmonic analysis and adaptive network-based fuzzy inference system model[J]. Acta Oceanologica Sinica, 2017, 36(11): 94–105.
- [18] BAO W, BIN W. Real-time tide prediction based on an hybrid HA– WANN model using wind information[C]//2018 14th IEEE International Conference on Signal Processing (ICSP). IEEE, 2018: 604– 608.
- [19] TU Z, GAO X, XU J, et al. A novel method for regional short-term forecasting of water level[J]. Water, 2021, 13(6): 820.
- [20] GAN M, PAN S, CHEN Y, et al. Application of the machine learning LightGBM Model to the prediction of the water levels of the Lower Columbia River[J]. Journal of Marine Science and Engineering, 2021, 9(5): 496.
- [21] CHEN Y, GAN M, PAN S, et al. Application of auto-regressive (AR) analysis to improve short-term prediction of water levels in the Yangtze estuary[J]. Journal of Hydrology, 2020, 590: 125386.
- [22] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735–1780.
- [23] WILLIAMS R J, ZIPSER D. A learning algorithm for continually running fully recurrent neural networks [J]. Neural Computation, 1989, 1(2):270–280.
- [24] JOZEFOWICZ R, ZAREMBA W, SUTSKEVER I. An empirical exploration of recurrent network architectures[C]//International Conference on Machine Learning. PMLR, 2015: 2342–2350.

- [25] BAO W, YUE J, RAO Y. A deep learning framework for financial time series using stacked autoencoders and long-short term memory[J]. PloS One, 2017, 12(7): e0180944.
- [26] FISCHER T, KRAUSS C. Deep learning with long short-term memory networks for financial market predictions[J]. European Journal of Operational Research, 2018, 270(2): 654–669.
- [27] KIM H Y, WON C H. Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models[J]. Expert Systems with Applications, 2018, 103: 25–37.
- [28] ZHENG H, YUAN J, CHEN L. Short-term load forecasting using EMD-LSTM neural networks with a Xgboost algorithm for feature importance evaluation[J]. Energies, 2017, 10(8):1168.
- [29] KIM T Y, CHO S B. Predicting residential energy consumption using CNN–LSTM neural networks[J]. Energy, 2019, 182: 72–81.
- [30] MA X, TAO Z, WANG Y, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data [J]. Transportation Research Part C: Emerging Technologies, 2015, 4: 187–197.
- [31] ZHAO Z, CHEN W, WU X, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68–75.
- [32] GUI G, HUANG H, SONG Y, et al. Deep learning for an effective nonorthogonal multiple access scheme[J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8440–8450.
- [33] 李靖宇,袁宾潞.长江口及浙江沿岸海洋经济区域与产业布局 优化问题探讨[J].中国地质大学学报(社会科学版),2007,7(2): 31-38.
- [34] 时钟. 长江口水动力过程的研究进展(1979-1999)[J]. 海洋科学,2001,25(6):54-57.
- [35] ZHANG E, SAVENIJE H H G, WU H, et al. Analytical solution for salt intrusion in the Yangtze Estuary, China[J]. Estuarine, Coastal and Shelf Science, 2011, 91(4): 492–501.
- [36] CHEN Z, XU K, WATANABE M. Dynamic hydrology and geomorphology of the Yangtze River[M]//Large rivers: geomorphology and management. Wiley Chichester, 2007: 457–469.
- [37] LEI Z Y, ZHANG J S, KONG J. Numerical simulation of water level under interaction between runoff and estuarine dynamics in tidal reach of the Yangtze River[J]. China Ocean Engineering, 2009, 23(3): 543–551.
- [38] YIN K, XU S, HUANG W. Estimating extreme sea levels in Yangtze Estuary by quadrature joint probability optimal sampling method[J]. Coastal Engineering, 2018, 140: 331–341.
- [39] 袁小婷,程和琴,郑树伟,等.近期长江大通至南京河段潮动力变 化趋势与机制[J].海洋通报,2019,38(5):553-561.
   (本文编辑:王少朋)